



Sveučilište u Zagrebu

FAKULTET STROJARSTVA I BRODOGRADNJE

Mr.sc. KREŠIMIR OSMAN, dipl. ing.

RAZVOJ TEHNIČKIH SUSTAVA TEMELJEM MODELA PONAŠANJA ARHITEKTURE SUSTAVA

DOKTORSKI RAD

Zagreb, 2014.



University of Zagreb

FACULTY OF MECHANICAL ENGINEERING AND NAVAL ARCHITECTURE

Mr.sc. KREŠIMIR OSMAN, dipl. ing.

**DEVELOPMENT OF TECHNICAL SYSTEMS BASED
ON BEHAVIOUR PREDICTION OF SYSTEM
ARCHITECTURE**

DOCTORAL THESIS

Zagreb, 2014.



Sveučilište u Zagrebu
FAKULTET STROJARSTVA I BRODOGRADNJE

Mr.sc. KREŠIMIR OSMAN, dipl. ing.

RAZVOJ TEHNIČKIH SUSTAVA TEMELJEM MODELA PONAŠANJA ARHITEKTURE SUSTAVA

DOKTORSKI RAD

Mentor:
Prof. dr. sc. Dorian Marjanović, dipl. ing.

Zagreb, 2014.



University of Zagreb

FACULTY OF MECHANICAL ENGINEERING AND NAVAL ARCHITECTURE

Mr.sc. KREŠIMIR OSMAN, dipl. ing.

DEVELOPMENT OF TECHNICAL SYSTEMS BASED ON BEHAVIOUR PREDICTION OF SYSTEM ARCHITECTURE

DOCTORAL THESIS

Supervisor:

Prof. dr. sc. Dorian Marjanović, dipl. ing.

Zagreb, 2014.

PODACI ZA BIBLIOGRAFSKU KARTICU:

UDK: 7.05: 62-112.5: 62-529

Ključne riječi:

ponašanje, predviđanje, složenost, tehnički sustav, neizvjesnost, Design Structure Matrix (DSM), arhitektura sustava, MPC metoda, stabilnost sustava, izravna metoda Ljapunova, neizrazita logika

Znanstveno područje: TEHNIČKE ZNANOSTI

Znanstveno polje: Strojarsvo

Institucija u kojoj je rad izrađen:

Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu

Mentor rada: dr. sc. Dorian Marjanović, red. prof.

Broj stranica: 207

Broj slika: 70

Broj tablica: 20

Broj korištenih bibliografskih jedinica: 148

Datum obrane: 28.07.2014.

Povjerenstvo:

dr. sc. Mario Štorga, izv. prof. – predsjednik povjerenstva

dr. sc. Dorian Marjanović, red. prof. – mentor

dr. sc. Tomaž Savšek, docent, Fakultet za industrijski inženjering, Novo Mesto, Slovenija – član povjerenstva

Institucija u kojoj je rad pohranjen:

Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu

ZAHVALA

Ovim putem zahvaljujem se svojem mentoru Prof. dr.sc. Dorianu Marjanoviću na neizmjernoj pomoći i susretljivosti, koju mi je pružio kroz sve ove godine, tijekom poslijediplomskog studija, kao i izrade samog doktorskog rada.

Zahvaljujem se Prof. dr.sc. Mariu Štorgi, na izuzetnom trudu, kroz savjete i pomoć u izradi ovog rada, te na primjedbama i sugestijama koje su poboljšale njegovu kvalitetu.

Uz to zahvaljujem se i Doc. dr. sc. Tomažu Savšek, sa Fakulteta za industrijski inženjering, Novo mesto, Slovenija, na savjetima, koji su pridonijeli tome da bi rad bio još bolji.

Želim se zahvaliti i Dr.sc. Tinu Stankoviću sa Univerziteta ETH Zurich, na izdvojenom vremenu koje je izdvojio za naše rasprave, te korisne savjete i sugestije.

Zahvaljujem se Prof. dr. sc. Milanu Opaliću, Prof. dr. sc. Nenadu Kranjčeviću i Doc. dr. sc. Krešimiru Vučkoviću sa Katedre za elemente strojeva i konstrukcije, Prof. dr.sc. Dragutinu Ščapu i Matiji Hoiću, mag.ing. sa Katedre za transportne uređaje i konstrukcije, Prof. dr.sc. Josipu Kasaću i Prof. dr.sc. Mladenu Crnekoviću sa Katedre za strojarsku automatiku, Prof. dr. sc. Hinku Wolfu sa Katedre za dinamiku mehaničkih sustava, Prof. dr. sc. Sanji Singer i Mr.sc. Peteru Gregoreku sa Katedre za matematiku, FSB Zagreb, te Prof. dr.sc. Mati Baotiću sa Zavoda za automatiku i računalno inženjerstvo, FER Zagreb, na vrlo korisnim savjetima i smjernicama, koje su doprinijele kvaliteti ovog rada.

Posebno se želim zahvaliti i svim ostalim, kako sadašnjim, tako i bivšim članovima Katedre za konstruiranje i razvoj proizvoda, te Laboratorija za konstruiranje – CADlab, s kojima sam imao priliku surađivati, na njihovoj pruženoj pomoći i savjetima.

Na kraju posebna zahvala ide mojim roditeljima Željki i Tomislavu, na neizmjernoj potpori i strpljenju, tijekom cijelog mog poslijediplomskog studija, svih ovih godina, da se on uspješno privede kraju.

SADRŽAJ

SADRŽAJ	I
POPIS SLIKA	IV
POPIS TABLICA	VIII
POPIS OZNAKA	X
POPIS KRATICA	XVII
PREDGOVOR	XVIII
SAŽETAK	XIX
SUMMARY	XX
1. UVODNA RAZMATRANJA	1-1
1.1.Motivacija za istraživanje	1-1
1.2.Cilj i svrha istraživanja	1-4
1.3.Hipoteza i istraživačka pitanja	1-5
1.4.Metodologija istraživanja	1-5
1.5.Očekivani znanstveni doprinos	1-7
1.6.Struktura doktorskog rada	1-8
2. PODRUČJE ISTRAŽIVANJA	2-1
2.1.Domensko preslikavanje	2-1
2.2.Neizvjesnost u konstruiranju	2-6
2.3.Sustav i složeni sustav	2-14
2.4.Arhitektura proizvoda	2-15
2.5.Dinamički sustavi	2-16
2.6.Stabilnost dinamičkih sustava	2-19
2.7.Odlučivanje u konstruiranju	2-20
2.8.Implikacije na rad	2-22
3. TEORETSKE OSNOVE ISTRAŽIVANJA	3-1
3.1.Pristup inženjerstva sustava	3-1
3.2.Metodologija konstruiranja mehatroničkih proizvoda (prema VDI 2206)	3-2
3.3.Teorija područja	3-5
3.4.Matematičko modeliranje dinamičkih sustava	3-6
3.5.Metoda modelskog prediktivnog upravljanja	3-11
3.6.Metode određivanja stabilnosti dinamičkih sustava po Ljapunovu	3-14
3.7. Sustavi odlučivanja bazirani na neizrazitoj logici	3-15
3.8. Implikacije na rad	3-16
4. PRIJEDLOG ALGORITMA RAZVOJA ARHITEKTURA SLOŽENIH TEHNIČKIH SUSTAVA	4-1
4.1.Prikaz algoritma	4-1
4.2.Modularizacija arhitekture sustava	4-4

4.3.	Modeliranje sustava	4-6
4.4.	Modelsko prediktivno upravljanje (MPC) metoda	4-13
4.4.1.	<i>Matematički modeli osnovnih vektora u MPC metodi</i>	4-13
4.4.2.	<i>Podešavanje parametara u MPC metodi</i>	4-14
4.4.3.	<i>Postupak računanja optimalnog predikcijskog vektora izlaza regulatora</i>	4-15
4.5.	Ispitivanje stabilnosti sustava	4-19
4.5.1.	<i>Ispitivanje stabilnosti kontinuiranih sustava</i>	4-19
4.5.2.	<i>Ispitivanje stabilnosti diskretnih sustava</i>	4-20
4.6.	Sustav odlučivanja baziran na neizrazitoj logici	4-22
4.6.1.	<i>Omekšavanje ili fazifikacija</i>	4-23
4.6.2.	<i>Inferencija ili proces neizrazitog odlučivanja</i>	4-24
4.6.3.	<i>Izoštavanje ili defazifikacija</i>	4-25
4.6.4.	<i>Lokalno i globalno zaključivanje</i>	4-26
4.7.	Zapis pravila ponašanja sustava	4-26
4.8.	Prijenos informacija između pojedinih operacija algoritma	4-26
4.9.	Implikacije na rad	4-27
5.	VERIFIKACIJA	5-1
5.1.	Primjena algoritma u razvoju elektromehaničkog sustava	5-2
5.1.1.	<i>Korak iteracije 1</i>	5-2
5.1.2.	<i>Dobiveni rezultati nakon koraka iteracije 1</i>	5-15
5.1.3.	<i>Tablični prikaz rezultata nakon koraka iteracije 1</i>	5-17
5.1.4.	<i>Korak iteracije 2</i>	5-17
5.1.5.	<i>Dobiveni rezultati nakon koraka iteracije 2</i>	5-23
5.1.6.	<i>Tablični prikaz rezultata nakon koraka iteracije 2</i>	5-25
5.1.7.	<i>Korak iteracije 3</i>	5-25
5.1.8.	<i>Dobiveni rezultati nakon koraka iteracije 3</i>	5-30
5.1.9.	<i>Tablični prikaz rezultata nakon koraka iteracije 3</i>	5-32
5.1.10.	<i>Korak iteracije 4</i>	5-32
5.1.11.	<i>Dobiveni rezultati nakon koraka iteracije 4</i>	5-38
5.1.12.	<i>Tablični prikaz rezultata nakon koraka iteracije 4</i>	5-40
5.2.	Primjena algoritma u razvoju toplinsko – hidrauličnog sustava	5-40
5.2.1.	<i>Korak iteracije 1</i>	5-41
5.2.2.	<i>Dobiveni rezultati nakon koraka iteracije 1</i>	5-53
5.2.3.	<i>Tablični prikaz rezultata nakon koraka iteracije 1</i>	5-55
5.2.4.	<i>Korak iteracije 2</i>	5-55
5.2.5.	<i>Dobiveni rezultati nakon koraka iteracije 2</i>	5-60
5.2.6.	<i>Tablični prikaz rezultata nakon koraka iteracije 2</i>	5-62
5.2.7.	<i>Korak iteracije 3</i>	5-62
5.2.8.	<i>Dobiveni rezultati nakon koraka iteracije 3</i>	5-68
5.2.9.	<i>Tablični prikaz rezultata nakon koraka iteracije 3</i>	5-70
5.2.10.	<i>Korak iteracije 4</i>	5-70
5.2.11.	<i>Dobiveni rezultati nakon koraka iteracije 4</i>	5-73

5.2.12. <i>Tablični prikaz rezultata nakon koraka iteracije 4</i>	5-75
5.3. <i>Implikacije na rad</i>	5-75
6. RASPRAVA	6-1
6.1. <i>Usporedba postavljenih ciljeva sa dobivenim rezultatima, te trenutnim stanjem tehnike</i>	6-1
6.1.1. <i>Primjer 1 – elektromehanički sustav – uređaj za dizanje tereta</i>	6-3
6.1.2. <i>Primjer 2 – toplinsko – hidraulični sustav – klima komora</i>	6-5
6.1.3. <i>Usporedba s trenutnim stanjem tehnike</i>	6-6
6.2. <i>Utvrđivanje mogućnosti primjene algoritma razvoja arhitektura složenih tehničkih sustava u realnom okruženju</i>	6-8
6.3. <i>Implikacije na rad</i>	6-9
7. ZAKLJUČAK	7-1
7.1. <i>Sažetak provedenog istraživanja</i>	7-1
7.1.1. <i>Objašnjenje</i>	7-2
7.1.2. <i>Analiza</i>	7-2
7.1.3. <i>Sinteza</i>	7-3
7.1.4. <i>Verifikacija</i>	7-3
7.1.5. <i>Rasprava</i>	7-3
7.2. <i>Ograničenja u istraživanju</i>	7-4
7.3. <i>Zaključak provedenog istraživanja</i>	7-5
7.4. <i>Smjerovi mogućih budućih istraživanja</i>	7-6
8. LITERATURA	8-1
ŽIVOTOPIS	1
CURRICULUM VITAE	2

- Slika 1.1. Struktura doktorskog rada prema metodologiji istraživanja
- Slika 2.1. Višedomensko preslikavanje u složenom dinamičkom sustavu
- Slika 2.2. Modeliranje ponašanja sustava kod višedomenskog preslikavanja
- Slika 2.3. Dijagram toka quad-I/HS okruženja
- Slika 2.4. Klasifikacija uzroka neizvjesnosti
- Slika 2.5. Osnovne vrste neizvjesnosti
- Slika 2.6. Klasifikacija osnovnih vrsti neizvjesnosti
- Slika 2.7. Podjela neizvjesnosti prema vrsti informacije
- Slika 2.8. Kategorije modela neizvjesnosti
- Slika 2.9. Klasifikacija metoda prema stupnju neizvjesnosti
- Slika 2.10. Tablični prikaz nekih metoda za upravljanje neizvjesnošću
- Slika 2.11. Općeniti proces odlučivanja u konstruiranju
- Slika 3.1. Metodologija konstruiranja mehatroničkih proizvoda (prema VDI 2206)
- Slika 3.2. Teorija područja
- Slika 3.3. Prikaz teoretskog i eksperimentalnog pristupa u kreiranju matematičkog modela sustava
- Slika 3.4. Hijerarhija matematičkih modela u razvoju mehatroničkih sustava
- Slika 3.5. Struktura poopćenog modelskog predikcijskog regulatora
- Slika 3.6. Osnovna arhitektura sustava odlučivanja pomoću pravila bazirana na neizrazitoj logici
- Slika 4.1. Algoritam razvoja arhitektura složenih tehničkih sustava sa svojim pojedinim operacijama
- Slika 4.2. Modularizacija arhitekture sustava
- Slika 4.3. Algoritam kreiranja matematičkog modela teoretskom analizom za obje ponašajne domene (kontinuiranu i diskretnu)
- Slika 4.4. Blok shema (prikaz) MIMO sustava

Slika 4.5. Osnovni princip rada metode modelsko prediktivno upravljanje za SISO sustav; slika a) prikazuje stanje sustava upravljanja u trenutku $t = kT$, a slika b) prikazuje stanje sustava upravljanja u trenutku $t = (k+1)T$

Slika 4.6. Algoritam MPC metode za obje ponašajne domene (kontinuiranu i diskretnu)

Slika 4.7. Algoritam ispitivanja stabilnosti sustava za obje ponašajne domene (kontinuiranu i diskretnu)

Slika 4.8. Shema sustava odlučivanja baziranog na neizrazitoj logici sa opisima pojedinih postupaka unutar njega

Slika 5.1. Početna (inicijalna) arhitektura sustava uređaja za dizanje tereta (korak iteracije 1)

Slika 5.2. Shematski prikaz sa oznakama pojedinih podsustava (korak iteracije 1)

Slika 5.3. Shematski prikaz podsustava 3 sa oznakama (korak iteracije 1)

Slika 5.4. Definirana neizrazita pravila ponašanja u koraku iteracije 1

Slika 5.5. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.6. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable n_M i v_V , c) rezultati globalnog zaključivanja za ulazne varijable i i v_V

Slika 5.7. Arhitektura sustava uređaja za dizanje tereta (korak iteracije 2)

Slika 5.8. Shematski prikaz sa oznakama pojedinih podsustava (korak iteracije 2)

Slika 5.9. Definirana neizrazita pravila ponašanja u koraku iteracije 2

Slika 5.10. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.11. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable n_M i v_V , c) rezultati globalnog zaključivanja za ulazne varijable i i v_V

Slika 5.12. Arhitektura sustava uređaja za dizanje tereta (korak iteracije 3)

Slika 5.13. Shematski prikaz sa oznakama pojedinih podsustava (korak iteracije 3)

Slika 5.14. Definirana neizrazita pravila ponašanja u koraku iteracije 3

Slika 5.15. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.16. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable n_M i v_V , c) rezultati globalnog zaključivanja za ulazne varijable i i v_V

Slika 5.17. Arhitektura sustava uređaja za dizanje tereta nakon dodavanja novih pravila ponašanja (korak iteracije 4)

Slika 5.18. Shematski prikaz sa oznakama pojedinih podsustava (korak iteracije 4)

Slika 5.19. Shematski prikaz podsustava 3 sa oznakama (korak iteracije 4)

Slika 5.20. Definirana neizrazita pravila ponašanja u koraku iteracije 4

Slika 5.21. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.22. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable n_M i v_V , c) rezultati globalnog zaključivanja za ulazne varijable i i v_V

Slika 5.23. Početna (inicijalna) arhitektura sustava klima komore (korak iteracije 1)

Slika 5.24. Shema grijača zraka za kreiranje matematičkog modela podsustava (zimsko razdoblje rada)

Slika 5.25. Shema hladnjaka zraka za kreiranje matematičkog modela podsustava (ljetno razdoblje rada)

Slika 5.26. Definirana neizrazita pravila ponašanja u koraku iteracije 1

Slika 5.27. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 1); a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.28. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 1); a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable T_V i q_z , c) rezultati globalnog zaključivanja za ulazne varijable q_z i $B \times H$

Slika 5.29. Arhitektura sustava klima komore (korak iteracije 2)

Slika 5.30. Shema rekuperatora zraka za kreiranje matematičkog modela podsustava

Slika 5.31. Shema ovlaživača zraka za kreiranje matematičkog modela podsustava

Slika 5.32. Definirana neizrazita pravila ponašanja u koraku iteracije 2

Slika 5.33. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 2); a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.34. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 2); a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable T_V i q_z , c) rezultati globalnog zaključivanja za ulazne varijable q_z i BxH

Slika 5.35. Arhitektura sustava klima komore (korak iteracije 3)

Slika 5.36. Shema rekuperatora zraka sa recirkulirajućim i obilaznim vodom za kreiranje matematičkog modela podsustava

Slika 5.37. Shema miješanja svježeg i recirkulirajućeg zraka

Slika 5.38. Definirana neizrazita pravila ponašanja u koraku iteracije 3

Slika 5.39. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 3); a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.40. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 3); a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable T_V i q_z , c) rezultati globalnog zaključivanja za ulazne varijable q_z i BxH

Slika 5.41. Arhitektura sustava klima komore nakon dodavanja novih pravila ponašanja (korak iteracije 4)

Slika 5.42. Definirana neizrazita pravila ponašanja u koraku iteracije 4

Slika 5.43. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 4); a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.44. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 4); a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable T_V i q_z , c) rezultati globalnog zaključivanja za ulazne varijable q_z i BxH

Tablica 2.1. Atributi neizvjesnosti

Tablica 2.2. Odnos arhitekture proizvoda o funkcijama proizvoda

Tablica 5.1. Prikaz raspona utjecajnih varijabli (u koracima iteracije 1 i 2)

Tablica 5.2. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koracima iteracije 1 i 2)

Tablica 5.3. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 1

Tablica 5.4. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 2

Tablica 5.5. Prikaz raspona utjecajnih varijabli (u koraku iteracije 3)

Tablica 5.6. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koraku iteracije 3)

Tablica 5.7. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 3

Tablica 5.8. Prikaz raspona utjecajnih varijabli (u koraku iteracije 4)

Tablica 5.9. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koraku iteracije 4)

Tablica 5.10. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 4

Tablica 5.11. Prikaz raspona utjecajnih varijabli (u koracima iteracije 1 i 2)

Tablica 5.12. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koracima iteracije 1 i 2)

Tablica 5.13. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 1

Tablica 5.14. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 2

Tablica 5.15. Prikaz raspona utjecajnih varijabli (u koracima iteracije 3 i 4)

Tablica 5.16. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koracima iteracije 3 i 4)

Tablica 5.17. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 3

Tablica 5.18. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 4

Latinične oznake:

$A \text{ [m}^2\text{]}$ – izmjenjivačka površina

\mathbf{A} – matrica dinamike sustava

$A \text{ [m}^2\text{]}$ – površina tereta

$A_H \text{ [m}^2\text{]}$ – izmjenjivačka površina zraka i stijenke cijevi,

$A_T \text{ [m}^2\text{]}$ – izmjenjivačka površina tople vode i stijenke cijevi

$A_u \text{ [m}^2\text{]}$ – površina poprečnog presjeka užeta

\mathbf{B} – matrica raspodjele upravljanja sustavom

\mathbf{C} – matrica mjerenja (senzora) sustava

$c \text{ [J/kgK]}$ – specifični toplinski kapacitet medija

$c \text{ [-]}$ – koeficijent zapreke

$c_{GV} \text{ [N/m]}$ – torzijska krutost gonjenog vratila

$c_u \text{ [N/m]}$ – krutost užeta

$c_v \text{ [J/kgK]}$ – specifični toplinski kapacitet vode

\mathbf{D} – matrica izravnog prolaza pobude na izlaz sustava

$D_B \text{ [m]}$ – promjer bubnja za dizanje tereta

$D_1 \text{ [mm]}$ – promjer zupčanika 1

$D_2 \text{ [mm]}$ – promjer zupčanika 2

$D_3 \text{ [mm]}$ – promjer zupčanika 3

$D_4 \text{ [mm]}$ – promjer zupčanika 4

$d_u \text{ [mm]}$ – promjer užeta

$dE \text{ [J]}$ – promjena entalpije promatranog volumena medija u vremenu dt

$dE_1 \text{ [J]}$ – količina topline dovedena promatranom volumena medija u vremenu dt

$dE_2 \text{ [J]}$ – količina topline odvedena promatranom volumena medija u vremenu dt

$d\Phi_{TH} \text{ [W]}$ – toplinski tok kroz djelić izmjenjivačke površine dA

$E \text{ [J]}$ – entalpija (ukupna toplinska energija)

E_k [J] – kinetička energija

E_p [J] – potencijalna energija

E_u [Pa] – modul elastičnosti užeta

F_{vj} [N] – sila vjetra

f – funkcija

G [Pa] – modul smicanja gonjenog vratila

H_I [W] – entalpija na izlazu iz podsustava

H_U [W] – entalpija na ulazu u podsustav

h [J/kgK] – specifična entalpija

h_{mz} [J/kg] – specifična entalpija vlažnog zraka na izlazu

h_{mz} [J/kg] – specifična entalpija vlažnog zraka na ulazu

h_{wv} [J/kg] – specifična entalpija vodene pare

I_P [m⁴] – polarni moment inercije

i [-] – ukupni prijenosni omjer u prijenosniku snage

i_1 [-] – prijenosni omjer prvog stupnja u prijenosniku snage

J_0 [kgm²] – dinamički moment inercije elektromotora

J_T [kgm²] – dinamički moment inercije tereta

J_1 [kgm²] – dinamički moment inercije zupčanika 1

J_2 [kgm²] – dinamički moment inercije zupčanika 2

J_2 [kgm²] – dinamički moment inercije zupčanika 2

J_3 [kgm²] – dinamički moment inercije zupčanika 3

J_4 [kgm²] – dinamički moment inercije zupčanika 4

J_5 [kgm²] – dinamički moment inercije bubnja

k_{GV} [Ns/m] – koeficijent viskoznog prigušenja gonjenog vratila

k_u [Ns/m] – koeficijent viskoznog prigušenja užeta

$k+N_1$ – trenutak u budućnosti od kojeg počinje smanjivanje odstupanja izlaza od referentne trajektorije

$k+N_2$ – trenutak u budućnosti do kojeg se smanjuje odstupanje izlaza od željene trajektorije

l_{GV} [m] – duljina gonjenog vratila
 L_u [m] – dužina užeta
 l_1 [m] – početna duljina užeta
 M_{EM} [Nm] – moment elektromotora
 m [kg] – masa promatranog volumena medija
 m_B [kg] – masa bubnja
 m_K [kg] – masa kuke
 m_0 [kg] – masa elektromotora
 m_T [kg] – masa tereta
 m_u [kg] – masa užeta
 m_1 [kg] – masa zupčanika 1
 m_2 [kg] – masa zupčanika 2
 m_3 [kg] – masa zupčanika 3
 m_4 [kg] – masa zupčanika 4
 N_1 – prvi predikcijski horizont
 N_2 – drugi predikcijski horizont
 N_U – upravljački horizont
 n – dimenzija stanja (broj varijabli stanja)
 n_M [min⁻¹] – broj okretaja elektromotora
 \mathbf{P} – simetrična pozitivno određena matrica
 p – dimenzija pobude (broj pobuda koje djeluju na sustav)
 \mathbf{Q} – simetrična pozitivno određena matrica
 Q_j [N] – poopćena sila
 q [N/m²] – pretlak zastoja
 q – dimenzija izlaza (broj izlaznih signala sustava)
 q_j – poopćena koordinata
 \dot{q}_j – brzina poopćene koordinate
 r_B [m] – polumjer bubnja za dizanje tereta

r_0 [m] – radijus elektromotora

q_{mv} [kg/s] – maseni protok vodene vode

q_{mzi} [kg/s] – izlazni maseni protok vlažnog zraka

q_{mzu} [kg/s] – ulazni maseni protok vlažnog zraka

q_{oz} [kg/s] – maseni protok otpadnog zraka

q_{sz} [kg/s] – maseni protok svježeg zraka

q_v [kg/s] – maseni protok vode

q_{wv} [kg/s] – maseni protok vodene pare

q_{zM} [kg/s] – maseni protok svježeg zraka nakon miješanja sa recirkulirajućim zrakom

q_z [kg/s] – maseni protok zraka

$r(k+j)$ – zadana referentna veličina sustava u trenutku $k+j$

T [K] – temperatura medija

t [s] – vrijeme

T_H [K] – srednja vrijednost temperature zraka unutar izmjenjivača

T_M [K] – temperatura svježeg zraka nakon miješanja sa recirkulirajućim zrakom

T_{ozi} [K] – izlazna temperatura otpadnog zraka

T_{ozu} [K] – ulazna temperatura otpadnog zraka

$T_H(A)$ [K] – temperatura hladnog medija na promatranom djeliću izmjenjivačke površine dA

T_T [K] – srednja vrijednost temperature tople vode unutar izmjenjivača

$T_T(A)$ [K] – temperatura toplog medija na promatranom djeliću izmjenjivačke površine dA

T_V [K] – vanjska temperatura

T_s [K] – srednja temperatura cijevne stijenke izmjenjivača

T_{szi} [K] – izlazna temperatura svježeg zraka

T_{szu} [K] – ulazna temperatura svježeg zraka

T_{vi} [K] – izlazna temperature tople vode

T_{vu} [K] – ulazna temperature tople vode

T_{zi} [K] – izlazna temperature zraka

T_{zu} [K] – ulazna temperature zraka

u – vektor pobude na sustav

u – vektor prošlih izlaza regulatora

u_k – vektori koji opisuju trenutno stanje procesa, u trenutku k

\hat{u} – predikcijski vektor izlaza regulatora (upravljačke veličine)

$V [m^3]$ – volumen medija

$V(x)$ – Ljapunovljeva funkcija

$v_V [m/s]$ – brzina vjetra

w – trenutačna referentna vrijednost

w – vektor referentne trajektorije (željeni izlaz procesa u budućnosti)

w – vektor točaka na željenoj trajektoriji izlaza

$w_z [m/s]$ – brzina zraka u klima komori

x – vektor stanja

$x_{mzi} [kg/kg]$ – sadržaj vlage u vlažnom zraku na izlazu

$x_{mzu} [kg/kg]$ – sadržaj vlage u vlažnom zraku na ulazu

$x_u [m]$ – produljenje užeta

$x_{wv} [kg/kg]$ – sadržaj vlage u vodenoj pari

$x_{zi} [kg/kg]$ – sadržaj vlage u vlažnom zraku na izlazu

$x_{zu} [kg/kg]$ – sadržaj vlage u vlažnom zraku na ulazu

\dot{x} – vektor derivacija stanja

$\dot{x}_u [m/s]$ – brzina produljenja užeta

y – vektor mjerenih prošlih izlaza procesa

y – vektor odziva sustava

y_k – vektori koji opisuju trenutno stanje procesa, u trenutku k

\hat{y} – predikcijski vektor izlaza procesa

$\frac{\partial V}{\partial \mathbf{x}}$ – parcijalna derivacija skalarne funkcije po vektoru

Grčke oznake:

α_{TH} [W/m²K] – koeficijent prijelaza topline između toplog i hladnog medija

β – težinski koeficijent referentne trajektorije

β_i – stupanj istinitosti premise

ΔV – diferencija funkcije

δ (j) – težinski faktor kojom se smanjuje odstupanje vektora y od vektora w u trenutku $k+j$ u budućnosti

ρ [kg/m³] – gustoća medija

ρ_u [kg/m³] – gustoća užeta

λ (j) – težinski faktor kojom se smanjuje promjena upravljačkog signala u trenutku $k+j$ u budućnosti

Φ [J] – Rayleigh-ova disipacijska energija

Φ_1 [W] – toplinski tok doveden mediju

Φ_2 [W] – toplinski tok odveden mediju

Φ_{HI} [W] – toplinski tok zraka na izlazu iz izmjenjivača

Φ_{HU} [W] – toplinski tok zraka na ulazu u izmjenjivač

Φ_{HS} [W] – toplinski tok koji stijenke cijevi preda zraku

Φ_o [W] – toplinski tok prema okolini

Φ_{TI} [W] – toplinski tok tople vode na izlazu iz izmjenjivača

Φ_{TU} [W] – toplinski tok tople vode na ulazu u izmjenjivač

Φ_{TS} [W] – toplinski tok koji topla voda preda stijenci cijevi

φ_0 [rad] – kut zakreta elektromotora

$\dot{\varphi}_0$ [rad/s] – kutna brzina elektromotora

$\ddot{\varphi}_0$ [rad/s²] – kutno ubrzanje elektromotora

φ_5 [rad] – kut zakreta bubnja za dizanje tereta

$\dot{\varphi}_5$ [rad/s] – kutna brzina bubnja za dizanje tereta

$\ddot{\varphi}_5$ [rad/s²] – kutno ubrzanje bubnja za dizanje tereta

φ_6 [rad] – kut zakreta užeta

$\dot{\varphi}_6$ [rad/s] – kutna brzina užeta

$\ddot{\varphi}_6$ [rad/s²] – kutno ubrzanje užeta

DMM – Domain Mapping Matrix

DRM – Design Research Methodology

DSM – Design Structure Matrix

DynS – DSM – Dynamical System - Design Structure Matrix

FIS – Fuzzy Inference System

GHSM – Generalized Hybrid State Model

MDM – Multiple Domain Matrix

MIMO – Multiple input/ multiple output

MPC – Model Predictive Control

SFB – Sonderforschungsbereich

SISO – Single input/ single output

TTS – Theory of Technical Systems

VDI – Verein Deutscher Ingenieure

PREDGOVOR

Ovaj doktorski rad dio je istraživanja na području unapređenja teoretskih osnova i računalne podrške razvoju tehničkih sustava. Rad je dio ukupnih istraživanja u sklopu znanstvenoga projekta br. 120–1201829–1828 "Modeli i metode upravljanja znanjem u razvoju proizvoda", što ga financira Ministarstvo znanosti, obrazovanja i sporta Republike Hrvatske. Očekuje se da bi razvoj algoritma za modeliranje i predviđanje ponašanja u radnoj okolini, prikazan u ovom radu, pomoći u razvoju novih i poboljšanju postojećih arhitektura složenih tehničkih sustava, preslikavanjem u oba smjera, iz strukturne u ponašajnu domenu i obrnuto. Algoritam je temeljen na prikazu dinamičkog ponašanja sustava i njegovog zapisa pravilima.

RAZVOJ TEHNIČKIH SUSTAVA TEMELJEM MODELA PONAŠANJA ARHITEKTURE SUSTAVA

Ključne riječi: ponašanje, predviđanje, složenost, tehnički sustav, neizvjesnost, arhitektura sustava, *Design Structure Matrix (DSM)*, MPC metoda, stabilnost sustava, izravna metoda Ljapunova, neizrazita logika

Istraživanjem se proučila mogućnost predviđanja odstupanja u ponašanju složenih tehničkih sustava u odnosu na ponašanje sustava s predviđenim radnim parametrima. Neočekivano (neizvjesno) ponašanje sustava u promjenljivoj radnoj okolini modelirana je: modelom arhitekture tehničkog sustava i modelom ponašanja tehničkog sustava. Model arhitekture sustava temelji se na matrici komponenata DSM (engl. *Design Structure Matrix*), matričnom zapisu komponenata sustava. Ponašanje sustava modelirano je prediktivnom metodom upravljanja. Obostrano preslikavanje podataka između modela omogućava modeliranje ponašanja sustava u neizvjesnim situacijama. Pomoću, u okviru istraživanja, razvijenog algoritma i postojećih računalnih alata, verificirani su rezultati istraživanja, na realnim primjerima složenih tehničkih sustava.

DEVELOPMENT OF TECHNICAL SYSTEMS BASED ON BEHAVIOUR PREDICTION OF SYSTEM ARCHITECTURE

Keywords: *behaviour, prediction, complexity, technical system, uncertainty, system architecture, Design Structure Matrix (DSM), MPC method, system stability, Ljapunov direct method, fuzzy logic*

The research explore the possibility of predicting deviation in the behaviour of complex technical systems in relation to the system behaviour with predicted operating parameters. Unexpected (uncertain) behaviour of a system in a variable operating environment was modelled with: a technical system structure model and a technical system behaviour model. The system structure model is based on a DSM (*Design Structure Matrix*), matrix record of system components. System behaviour was modelled using a predictive control method. Bilateral data mapping between models enable system behaviour modelling in uncertain situations. Using an algorithm developed within the research and existing computing tools, research results were verified using real examples of complex technical systems.

UVODNA RAZMATRANJA

U prvom poglavlju prikazana je motivacija koja je potaknula istraživanje. Definirani su cilj i svrha istraživanja, te je dan prikaz hipoteze rada i istraživačkih pitanja, kao i prikaz metodologije istraživanja koja je upotrijebljena u ovom doktorskom radu. Očekivani znanstveni doprinos i struktura dokorskog rada opisani su na kraju poglavlja.

1.1. Motivacija za istraživanje

Broj izazova s kojima se suočavaju tvrtke posljednjih godina dramatično raste. Izazovi uglavnom proizlaze iz kontinuiranih promjena situacija na tržištu uslijed globalizacije i pritom se brzo odražavaju kako na međunarodnu konkurenciju, skraćene životne cikluse proizvoda, tako i na sam napredak tehnologije [1]. Pored toga, povećavaju se i zahtjevi kupaca koji uključuju i individualizirane varijante proizvoda, koje tvrtke svojim proizvodnim asortimanima trebaju zadovoljiti. Da bi održale konkurentnost tvrtke takve zahtjeve ne mogu zanemariti [2].

Povećani broj varijanti proizvoda znači i veću složenost samih procesa razvoja proizvoda [3]. Može se reći da presudan faktor uspješnosti tvrtki u industrijskom sektoru proizlazi iz sposobnosti razumijevanja i rukovanja složenim sustavima, kao i njihovim procesima razvoja, te neprestanim usvajanjem novih tehnologija. Tako skupljeno znanje treba iskoristiti kao konkurentnu prednost u razvoju i poboljšanju proizvoda. No u današnje vrijeme to postaje sve teže, upravo zbog drastičnog porasta složenosti sustava (proizvoda) [4].

Prema *Strogatz*-u [5] složenost sustava može se manifestirati u: strukturi sustava i dinamiци ponašanja sustava. *Strogatz* navodi da vrlo male promjene kod složenih sustava mogu dovesti do neželjene ili neočekivane arhitekture sustava, odnosno do neželjenog ili nestabilnog ponašanja sustava. Stoga vrlo je važno imati osnovno znanje o oba tipa složenosti sustava. Uz to treba znati opisati arhitekturu sustava, kao i modelirati njegovo ponašanje iz razloga boljeg razumijevanja samog sustava ([6], [7]). Kod kreiranja novih varijanti sustava ili poboljšanja postojećih, promjenom arhitekture sustava, dodavanjem funkcija ili podsustava, možemo utjecati na njegovo ponašanje. Stoga arhitektura sustava utječe i na fleksibilnost pri korištenju njegovih varijanti [8]. Varijante sustava mogu biti tako konfigurirane da tokom svog rada mogu pokazivati različite sposobnosti.

Arhitektura proizvoda ima utjecaj i na mnoge druge aspekte, poput kvalitete tehničkih sustava i procesa, od tehničkih svojstava, proizvodnih troškova, kao i na kasnije zadovoljenje zahtjeva tokom životnog ciklusa. Uz to ima i veliki raspon utjecaja na uspjeh proizvoda i firme. Tokom ranih faza razvoja proizvoda, ima utjecaja i na znatni dio troškova, prilikom dovođenja proizvoda na tržište. Međutim, vrlo je teško identificirati “dobre” arhitekture proizvoda [9].

Konstruiranje se može opisati kao proces transformacije skupa potreba i zahtjeva u opis tehničkog sustava ([10], [11]). U prostoru određenom zahtjevima korisnika, konstruktor iterativno napreduje od apstraktne ideje i koncepta do konkretno oblikovanog i detaljiranog rješenja. Iterativnost karakterizira niz petlji u kojima se izmjenjuje generiranje i validacija rješenja, temeljem kojih konstruktor odlučuje o nekim budućim rješenjima. Proces konstruiranja započinje s nepreciznim, nekompletnim i često kontradiktornim informacijama o budućem proizvodu te je pritom svaka pojedinačna alternativa rješenja zamišljena kao transformacija skupa kriterija i/ili zahtjeva u teoretsko ili fizičko rješenje, uključujući pritom i iskustvo konstruktora. Odluke donesene tokom preliminarnih faza razvoja proizvoda imaju značajan utjecaj na proizvod (npr. vrijeme razvoja proizvoda uz kvalitetu i cijenu proizvoda). Donošenje odluka otežavaju neizvjesnosti i nedorečenosti, koje su imanentne početnim fazama razvoja proizvoda [12].

Zbog napretka tehnologije i adaptacija tijekom primjene tehnički sustavi mogu se naći u radnom okruženju koje nije obuhvaćeno inicijalnim specifikacijama pa dolazi do neizvjesnih radnih uvjeta (npr. rad uređaja za dizanje tereta uslijed velikih brzina vjetra ili rad klima komore pri niskim vanjskim temperaturama).

Uz to u početnim fazama razvoja proizvoda postoje mnogi neizvjesni parametri, stoga se tu oni moraju sagledati kao takvi prilikom evaluacije alternativa proizvoda, te donošenja odluka [13].

U različitim fazama razvoja proizvoda, na različitim se razinama isprepleću dva utjecajna aspekta: kreiranje arhitekture sustava i paralelno vrednovanje ponašanja predložene arhitekture ([10], [14]). Konstruktori se tokom svog rada vrlo često susreću sa evaluacijama proizvoda s parametrima čije su vrijednosti neizvjesne.

U svakoj fazi razvoja proizvoda potrebno je provesti validaciju alternativa varijanti proizvoda, koja su nečesto bazirane na višestrukim kriterijima [13].

Validacija je posebno važna u konceptualnoj fazi razvoja proizvoda. Tada možemo izbjeći eventualne pogreške u konstruiranju, odnosno riješiti ih prije nego li su utjecale i na kasnije faze razvoja. Posebito je važno kod razvoja proizvoda rješavanje problema vezanih uz neizvjesnost uslijed okolišnih utjecaja (prirodna neizvjesnost – engl. *Environmental uncertainty*) [13]. Rješavanje takvih problema je vrlo teško bez poznavanja ponašanja tehničkih sustava i mogućnosti njihovog matematičkog modeliranja. To opet ovisi i o tipu tehničkog sustava, sagledavajući ga sa strane njegovog ponašanja. Preciznije možemo reći o tipu dinamičkog sustava (tj. da li je on tipa izrazito linearnog sustava ili je recimo izrazito nelinearan). Uz sve to treba uzeti u obzir i vanjska svojstva tog sustava. Tokom pojave takvih situacija, klasični pristupi daju nezadovoljavajuće rezultate iz razloga što oni ne pružaju kvantitativnu usporedbu varijanti proizvoda, da bi se dobila ona koja je prihvatljiva. Uz to, današnji procesi validacije proizvoda postaju sve složeniji. Razlozi su višestruki, ali ovdje ćemo istaći dva [15]: povećanje složenosti zahtjeva kupaca, te povećane tehničke mogućnosti proizvođača opreme.

Pored toga multidisciplinarnost, integriranje više struka (strojarstvo, elektronika, računarstvo, održavanje) pri razvoju današnjih proizvoda (kao što su npr. mehatronički sustavi), povećava složenost procesa validacije [16]. Upravo zbog složenosti procesa validacije, kao i multidisciplinarnosti u razvoju današnjih proizvoda (uvođenja novih trendova), potrebno je uzeti u obzir kod novih pristupa u razvoju i validaciji arhitektura složenih tehničkih sustava.

Tvrtke tokom procesa razvoja proizvoda moraju osigurati svojstva širokoj paleti proizvoda iz svog asortimana. Tu se javlja problem, jer te tvrtke maju vrlo male kapacitete da analiziraju cjelokupni asortiman svojih proizvoda.

Jedna od mogućnosti koja im se pritom pruža je da se tokom razvoja se oslanjaju i na prikupljeno iskustvo iz prošlih projekata ([15], [16]).

U posljednjih nekoliko godina predstavljena su dva pristupa u razvoju i validaciji alternativa arhitektura tehničkih sustava. Jedan pravac pristupa bazira se na tzv. robusnom konstruiranju ([15], [17], [18]) (engl. *Robust Design* – temeljen je uglavnom na metodama koje je razvio *Taguchi* [19]), gdje se integriraju postojeći modeli i metode u razvoju proizvoda. Drugi pristup, tzv. višedomensko preslikavanje (engl. *Multi-Dynamic Mapping*) ([4], [7], [20], [21]) pak integrira prema prije spomenutom *Strogatz*-u strukturnu i dinamičku složenost, uz obostrano preslikavanje informacija između domene strukture i domene ponašanja.

Oba pristupa imaju prednosti i nedostatke koji se manifestiraju, često raznoliko, ovisno o domeni sustava. Više o navedenim pristupima bit će dano u poglavlju 3 ovog doktorskog rada. Neovisno o primjeni domene sustava najvažnijim nedostatkom se čini da oba pristupa ne podržavaju nestacionarni prikaz ponašanja arhitektura tehničkih sustava.

Takav prikaz bi omogućio prikaz promjena utjecajnih varijabli tijekom rada tehničkih sustava u realnim radnim uvjetima. Mogućnost matematičkog modeliranja ponašanja sustava u nestacionarnom obliku dao bi nam i mogućnost uključivanje vanjskih uvjeta (tj. prirodnu neizvjesnost (engl. *Environmental uncertainty*) u matematički model tehničkog sustava. Time bismo mogli simulirati njegovo ponašanje uz podešavanje utjecajnih parametara, kao i mogućnost ispitivanja stabilnosti tehničkog sustava.

1.2. Cilj i svrha istraživanja

Inicijalni cilj prikazanog istraživanja je razvoj algoritma za modeliranje i previđanje ponašanja tehničkog sustava, u radnoj okolini, a koji se temelji na prikazu dinamičkog ponašanja sustava i zapisa tog ponašanja pomoću pravila. Algoritam treba pomoći u razvoju novih, te poboljšanju postojećih struktura složenih sustava, preslikavanjem u oba smjera, iz strukturne u ponašajnu domenu i obrnuto. Pritom treba reći da provedenim istraživanjem nije predviđen razvoj novih metoda modeliranja, već novi algoritam za opis arhitekture složenih tehničkih sustava. Uz primjenu postojećih metoda modeliranja, algoritam će omogućiti i predviđanje ponašanja u radnoj okolini.

Tokom rada u svojoj okolini tehnički sustav može biti izložen i neizvjesnim uvjetima. Stoga će algoritam obuhvatiti i takve radne uvjete. Na osnovu informacija dobivenih vrednovanjem ponašanja arhitektura složenih tehničkih sustava, kreiraju se pravila ponašanja.

1.3. Hipoteza i istraživačka pitanja

Navedeni ciljevi i svrha istraživanja odražavaju ovakvu hipotezu rada (pretpostavku istraživanja):

Modeliranjem značajki koje opisuju strukturu i odzive tehničkih sustava moguće je u fazi razvoja arhitekture sustava predvidjeti stabilnost potencijalnih izvedenica sustava u neočekivanim radnim uvjetima. Cikličkim povezivanjem modela strukture i ponašanja sustava moguće je unaprijediti arhitekturu tehničkih sustava.

U ovom radu istraživanje je usredotočeno na pronalaženju slijedećih istraživačkih pitanja koja su proizašla iz navedene hipoteze. Istraživačka pitanja su:

1. Kako opisati predložene arhitekture složenih tehničkih sustava?
2. Kako matematički opisati ponašanje arhitektura složenih tehničkih sustava u radnim i neizvjesnim uvjetima rada?
3. Koje informacije se tokom procesa preslikavanja prenose iz strukturne u ponašajnu domenu i obrnuto?
4. Koje metode odabrati za opis ponašanja arhitektura složenih tehničkih sustava?
5. Kako vrednovati predloženu arhitekturu složenog tehničkog sustava na temelju njegovog ponašanja?
6. Kako zapisati ponašanje novo razvijenih i poboljšanih arhitektura složenih tehničkih sustava?

1.4. Metodologija istraživanja

Metodologija prikazanog istraživanja temelji se na modificiranoj deskriptivnoj DRM metodologiji (engl. *Design Research Methodology*), prema autorima *Blessing i Chakabarti* [22]. Plan istraživanja stoga se može opisati sljedećim koracima:

1. *Obrazloženje* – kojim se argumentira motivacija istraživanja, te definira hipoteza rada, čime su postavljeni kriteriji i granice istraživanja. Uz to daje se pregled postojeće znanstvene i stručne literature unutar područja kako bi se opravdali i razjasnili ciljevi i svrha istraživanja.

Prikupljenim činjenicama utvrđuje se postojeće stanje na području neizvjesnosti u razvoju složenih tehničkih sustava, kao i obostranog preslikavanja između strukturne i ponašajne domene, i obrnuto, tj. područja koje se želi unaprijediti predloženim istraživanjem.

2. *Analiza* – obuhvaća razmatranje teoretskih osnova potrebnih za razvoj algoritma kojim se predviđa ponašanje pri razvoju arhitektura složenih tehničkih sustava, na temelju prikupljenih činjenica iz prethodnog koraka. Pri tome će biti objašnjene metode i metodologije u procesu konstruiranja, kao i teorije modeliranja proizvoda. Uz to će se posebno razmatrati različite metode odlučivanja u procesima konstruiranja, metode preslikavanja među domenama, kao i metode vođenja i provjere stabilnosti sustava kako bi se odabrale odgovarajuće teoretske podloge potrebne za razvoj algoritma.

Upravo zbog prirode složenih tehničkih sustava, potreban je multidisciplinarni pristup u istraživanju i analizi rezultata istraživanja. Pritom će se analizirati rezultati istraživanja iz raznih znanstvenih disciplina čije bi spoznaje mogle pridonijeti ovome istraživanju. Neke od znanstvenih disciplina koje će se razmotriti jesu: teorija signala i sustava, automatsko upravljanje, teorija stabilnosti i neizrazita logika.

3. *Sinteza* – kojom se predlaže implementacija teoretskih osnova metoda utvrđenih u prošlom koraku. Prvo će se pristupiti definiranju pojedinih operacija algoritma, te opisu i izradi matematičkih modela u pojedinim metodama.

4. *Verifikacija* – verifikacija algoritma provodi vrednovanje rezultata istraživanja analizom na odabranim primjerima realnih tehničkih sustava. Opis arhitekture sustava bit će izveden u postojećem računalnom alatu za menadžment složenim strukturama u matričnom zapisu. Temeljem dobivenih podsustava, pristupit će se njihovom matematičkom modeliranju i prikazu u prostoru stanja. Nakon toga izvršiti će se simulacija modelskog predikcijskog upravljanja sustava u nestacionarnom stanju, uz provjeru stabilnosti tehničkog sustava pomoću Ljapunovljeve metode. Na osnovu dobivenih rezultata dat će se zapis pravila ponašanja sustava u stacionarnom stanju koristeći metode neizrazite logike odlučivanja.

Izvedba modela ponašanja sustava bit će izvedena u postojećem računalnom alatu za simulaciju ponašanja sustava.

5. *Rasprava* – kojom se uspoređuju postavljeni ciljevi istraživanja s postignutim rezultatima i stanjem tehnike, te utvrđuju mogućnosti primjene u realnom okruženju, ali i daljnjeg razvoja.

1.5. Očekivani znanstveni doprinos

Od istraživanja prikazanog u ovom doktorskom radu očekuje se dvojak znanstveni doprinos. Kao prvo očekuje se da odgovori na postavljena istraživačka pitanja i pritom stvori pretpostavke za prijedlog algoritma razvoja arhitektura složenih tehničkih sustava koji će omogućiti: opis arhitektura složenih tehničkih sustava, prikaz matematičkog modela arhitektura složenih tehničkih sustava, odabir informacija koje se tokom procesa preslikavanja prenose iz strukturne u ponašajnu domenu i obrnuto, opis i vrednovanje ponašanja predloženih arhitektura složenih tehničkih sustava, te zapis ponašanja tih istih sustava.

Originalni doprinos ovog rada je u kreiranju algoritma razvoja arhitektura složenih tehničkih sustava, koji će se temeljiti na teoretskim osnovama i provedenom istraživanju. Od predloženog algoritma očekuje se da bude:

- otvoren, proširiv i fleksibilan – time se omogućava nadogradnja predloženog algoritma, kao i njegova prilagodba,
- prilagođen inženjerskom načinu razmišljanja – time bi se osiguralo da se algoritam može praktično primjenjivati,
- neovisan o korištenim računalnim alatima, koji se koriste u implementaciji algoritma.

U sklopu istraživanja koje je provedeno u okviru ovog dokorskog rada očekuju se doprinosi u teorijskom i primijenjenom dijelu. Razvoj algoritma za predviđanje ponašanja tehničkih sustava trebao bi pomoći konstruktorima da brže i učinkovitije riješe probleme razvoja arhitektura složenih sustava. Algoritam bi se koristio u početnim fazama razvoja proizvoda.

Rezultati istraživanja očekuju se prikazani kroz:

- a) teorijski doprinos, koji proizlazi iz algoritma temeljenog na procesu preslikavanja iz strukturne u ponašajnu domenu i obrnuto.
- b) primijenjeni dio doprinosa, koji se odnosi na primjenu algoritma na realnim primjerima arhitektura složenih tehničkih sustava, kojima će se vrednovati rezultati istraživanja.

Algoritam će se uz to usporediti i sa nekom/im sličnim algoritmima, metodama, pristupima ili metodologijama iz znanstvene literature. Kao realni primjeri složenih tehničkih sustava odabrani su: elektromehanički sustav (uređaj za dizanje tereta) i toplinsko – hidraulični sustav (klima komora).

1.6. Struktura doktorskog rada

Doktorski rad je podijeljen je u pet cjelina (prikazano na slici 1.1.) sukladno metodologiji istraživanja izloženoj pod točkom 1.4. ovog poglavlja.

Prva cjelina vezana uz obrazloženje, obrađena je u prvom i drugom poglavlju ovog rada. U 1. poglavlju, izložena su: motivacija istraživanja, cilj i svrha istraživanja, hipoteza i istraživačka pitanja, metodologiju istraživanja, te očekivani znanstveni doprinos. Drugo poglavlje izlaže pregled u području domenskog preslikavanja i neizvjesnosti u konstruiranju, te pobliže objašnjava osnovne pojmove: sustav i složeni sustav, arhitekturu proizvoda, dinamičke sustave, stabilnost dinamičkih sustava, te odlučivanje u konstruiranju.

Druga cjelina obrađuje analizu disertacije, a obuhvaćena je 3. poglavljem. Uz teoretske osnove kao polazište istraživanja, dan je kratak pregled inženjerstva sustava, te metodologije konstruiranja mehatroničkih proizvoda. Slijedi opis teorije područja, te opis modeliranja dinamičkih sustava. Dan je i kratki pregled metode prediktivnog upravljanja (MPC), te metoda određivanja stabilnosti dinamičkih sustava. Na kraju su ukratko opisani sustavi odlučivanja bazirani na neizrazitoj logici.

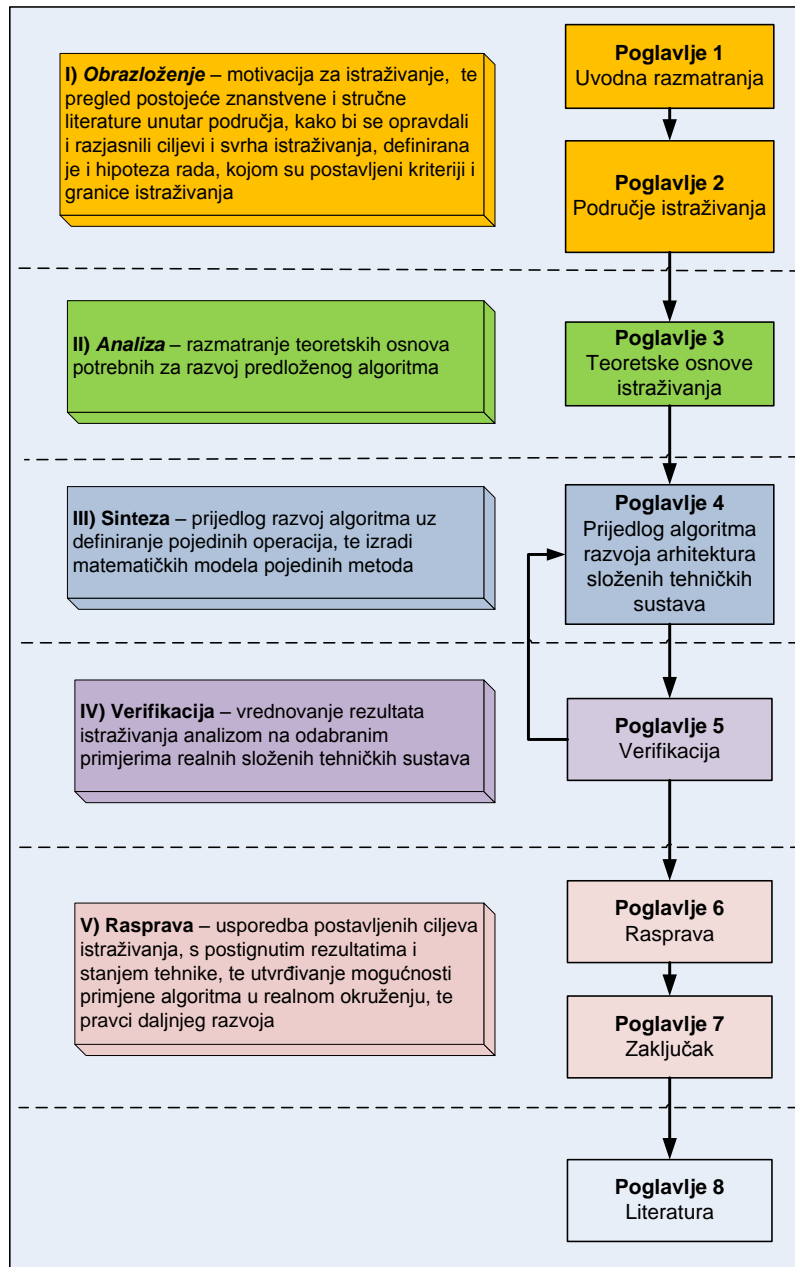
Sintezom provedenih istraživanja dan je prijedlog algoritma za razvoj arhitektura složenih tehničkih sustava, koji je opisan u 4. poglavlju. U tom je poglavlju objašnjen razvoj algoritma. Uz definiranje pojedinih operacija algoritma, opisani su i prikazani pojedini matematički modeli vezani uz svaku navedenu operaciju. Najprije je objašnjen princip opisa arhitekture tehničkih sustava pomoću DSM-a, te principi kreiranja matematičkog modela ponašanja tehničkih sustava u prostoru stanja. Uz to je opisan i prikazan model MPC metode, te model ispitivanja stabilnosti sustava izravnom metodom Ljapunova. Cjelina završava modelom sustava odlučivanja baziranog na neizrazitoj logici. Svaka operacija prikazana je dijagramom toka.

Verifikacija algoritma, uz vrednovanje rezultata istraživanja na odabranim realnim primjerima tehničkih sustava s prikazom dobivenih rezultata, izložena je u 5. poglavlju. Kao realni primjeri odabrani su elektromehanički sustav (uređaj za dizanje tereta) i toplinsko – hidraulični sustav (klima komora).

Rasprava izloženih rezultata istraživanja obuhvaćena je poglavljima 6 i 7.

U 6. poglavlju uspoređuju se postavljeni ciljevi istraživanja koji se uspoređuju s dobivenim rezultatima, te postojećim stanjem tehnike. Uz to utvrđuje se mogućnost primjene algoritma u realnom okruženju. Sedmo poglavlje, daje nam uz kratki sažetak prikazanog istraživanja i ograničenja koja su se javila tijekom istraživanja, zaključak, te moguće pravce daljeg istraživanja.

Popis korištene literature u doktorskom radu dan je na kraju rada.



Slika 1.1. Struktura doktorskog rada prema metodologiji istraživanja

PODRUČJE ISTRAŽIVANJA

U ovom poglavlju pobliže je izložen pregled područja istraživanja u području domenskog preslikavanja, tj. povezivanju modela strukture i modela ponašanja sustava. Modeli se ciklički povezuju sa ciljem razvoja i poboljšanja arhitektura složenih tehničkih sustava. Uz to izložen je i kratak pregled istraživanja u području neizvjesnosti u konstruiranju. Nadalje pobliže su objašnjeni i osnovni pojmovi, vezani uz definirano područje istraživanja: sustav i složeni sustav, arhitektura proizvoda, dinamički sustavi, stabilnost dinamičkih sustava, te odlučivanje u konstruiranju.

2.1. Domensko preslikavanje

Za modeliranje strukture sustava, često se primjenjuju matrične metode. U literaturi se navodi veliki broj matrično baziranih metoda koje se primjenjuju u razvoju proizvoda ([23], [24]).

U literaturi se mogu naći različite klasifikacije tih metoda (po količini uključenih vrsta elemenata, te po broju izvršenih proračuna), no zajednička im je značajka da se baziraju na teoriji grafova [25].

Neke od matričnih metoda fokusirane su na prezentiranje i analizu između elemenata istog tipa (npr. zavisnosti između fizičkih komponenti proizvoda), dok druge pak promatraju veze između dvije različite vrste elemenata (npr. zavisnosti između zahtjeva kupaca i funkcija proizvoda).

Ako se radi o relacijama između elemenata koji pripadaju istoj vrsti, tada se tako povezane matrice mogu definirati kao *unutar-domenske* (engl. *Intra-domain*). Matrice koje kombiniraju različite elemente koji pripadaju različitim domenama nazivaju se *van-domenske matrice* (engl. *Inter-domain Matrices*) ([23], [24]).

Najčešći primjenjivana metoda unutar-domenske matrice u literaturi je *DSM* (engl. *Design (Dependency) Structure Matrix*). *Steward* je definirao prvi put pojam DSM-a u svojoj publikaciji 1981. godine [26]. Prema opisu koju daje *Browning* [27]: DSM je kvadratna matrica, tj. ima jednaki broj redaka i stupaca. Ona omogućuje sustavno preslikavanje (mapiranje) elemenata i njihovih međusobnih odnosa. Ti elementi mogu biti, na primjer, fizičke komponente proizvoda, performanse atributa, inženjerski zahtjevi, odnosno zadaci u procesu. DSM-om je moguće ostvariti i dekomponiranje sustava u podsustave (module).

Ako se kombinira upotreba unutar i van-domenskih matrica, te kada su pritom napravljeni proračuni podskupova informacija u jednoj domeni matrice prema podskupovima informacija koji su sadržani u drugim domenama, tada takav pristup nazivamo *Višedomenska matrica* (engl. *Multiple-Domain Matrix - MDM*) ([23], [24]). *MDM* su prvi uveli *Maurer* i *Lindemann*, koji napominju da se njihov pristup temelji na kombinaciji DSM i *Matrice preslikavanja između domena* (engl. *Domain Mapping Matrix - DMM*) metoda ([28] – [32]). Time se omogućuju i različiti pogledi na sustav u jednom modelu.

S druge pak strane u modeliranju *dinamike sustava* (engl. *System Dynamics*) ([33] – [35]), često se koriste modeli *hibridnih dinamičkih sustava* (engl. *Hybrid Dynamical Systems*) [36]. Dinamika tih sustava može se općenito opisati kao povezivanje kontinuiranih i diskretnih podsustava, odnosno kao njihova kombinacija. To omogućuje modeliranje širokog raspona sustava, uključujući u to i industrijske procese. U literaturi su razvijeni takvi modeli koji kombiniraju dva osnovna matematička prikaza: obične diferencijalne jednadžbe i diskretne događaje ili Petrijeve mreže [36].

Međutim oba navedena pristupa su ograničena u svojim primjenama. Model strukture prikazan matričnim metodama ne može opisati ponašanje sustava, dok se modelom hibridnog dinamičkog sustava ne mogu prikazati interakcije u sustavu, kao i primjena na velike ili složene sustave [7].

Stoga je od autora *Diepold i ostali* predložen novi pristup, tzv. *višedomensko preslikavanje* (engl. *Multi-Dynamic Mapping*) ([4], [7]), koji kombinira modele strukture i ponašanja sustava, prikazom u jedinstvenom modelu sustava. Također pristup omogućuje da se oba tipa složenosti razmatraju odvojeno preko zasebnih modela.

Pristup koji omogućuje prikaz svih mogućih dinamičkih interakcija zapisom u jednoj paradigmi je tzv. *Višehibridni sustav* (engl. *Multi-hybrid System*) [7]. Pristup se temelji na modelu koji se zove *općeniti model hibridnog stanja* (engl. *Generalized hybrid state mode – GHSM*) [4], a proširenje je *hibridnog modela stanja* (engl. *Hybrid state model – HSM*) ([36], [37]), koji je primjenjiv na složene sustave.

Pristup višedomenskog preslikavanja omogućuje obostrano preslikavanje između višedomenske matrice (MDM) i višehibridnog sustava.

Kod GHSM modela postoji mogućnost prikaza dinamičkih domena, no još uvijek samo u stacionarnom slučaju, tj. kada promjene u sustavu nisu vremenski promjenjive. GHSM model omogućuje nam da ponašanje sustava prikažemo kroz nekoliko dinamičkih domena. Model se sastoji od 3 dinamičke domene (podsustava) ([4], [7]): *kontinuirana domena* (engl. *Continuous domain*), *diskretna domena* (engl. *Discrete domain*) i *domena konačnih automata* (engl. *Finite automation domain*). Kontinuirana domena prikazuje kontinuiranu promjenu varijabli u sustavu prikazom korištenjem običnih diferencijalnih jednadžbi, dok diskretna domena prikazuje diskretne promjene varijabli u sustavu, korištenjem klasičnih diskretnih dinamičkih jednadžbi. Domena konačnih automata sadrži konačan broj stanja sustava, koristeći pritom minimum znanja. Omogućava promjenu iz jednog (trenutnog) stanja u drugo stanje. Domene su međusobno povezane putem tzv. *funkcija preslikavanja (prijelaza)* (engl. *Mapping functions, Jumping maps*) ([4], [7]).

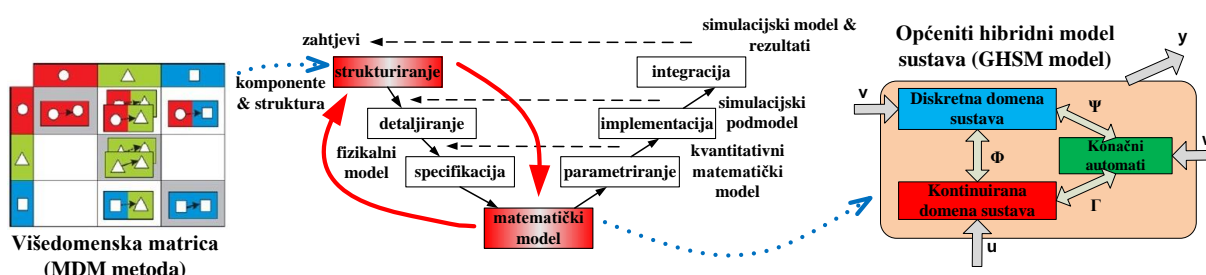
Pristup višehibridnog sustava omogućuje upravljanje bilo kojim tipom znanja (funkcionalno, proporcionalno, ekspertno i lingvističko), integrirajući ga u matematički model i tada ga koristeći u dinamičkoj analizi sustava [7].

Kasnije su *Diepold i ostali* pristup višedomenskog preslikavanja proširili na tzv. *Dinamički DSM* (engl. *Dynamical System DSM – DynS - DSM*) pristup ([20], [37]).

U njemu se zadržavaju svojstva analize strukture sustava (tj. DSM-a), tokom cijele procedure modeliranja, što na kraju rezultira dinamičkim prikazom u diskretnom vremenu u stacionarnom slučaju. Efekti promjena u strukturi se direktno transformiraju u prikaz dinamike sustava, koristeći optimizaciju spregnutih sustava. Pristup kombinira kvalitativne i kvantitativne modele, zadržavajući pritom ravnotežu između simulacija i teoretske analize.

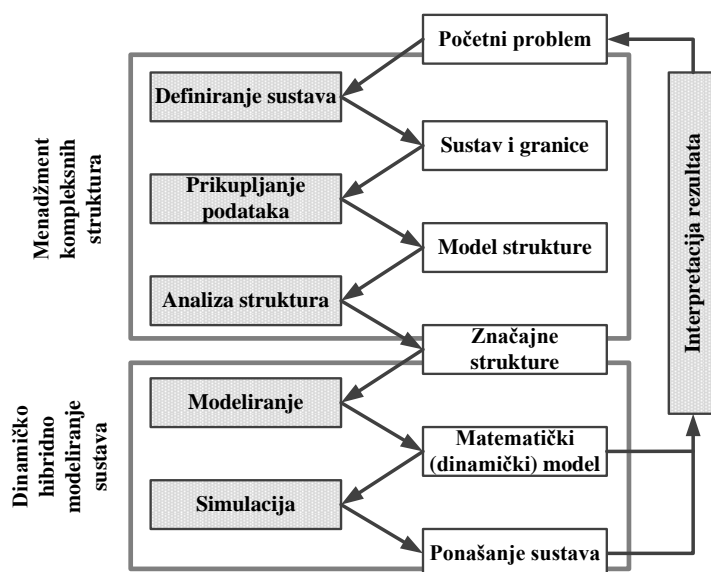
Kvaliteta teoretske analize, kao i simulacija, ovise o nivou detalja interakcija u sustavu ([4], [7], [20]).

Također se omogućuje i smanjenje reda sustava tokom pristupa. Na slici 2.1. prikazan je pristup modeliranja (višedomenskog preslikavanja) [7], putem V-modela [38] složenih sustava.



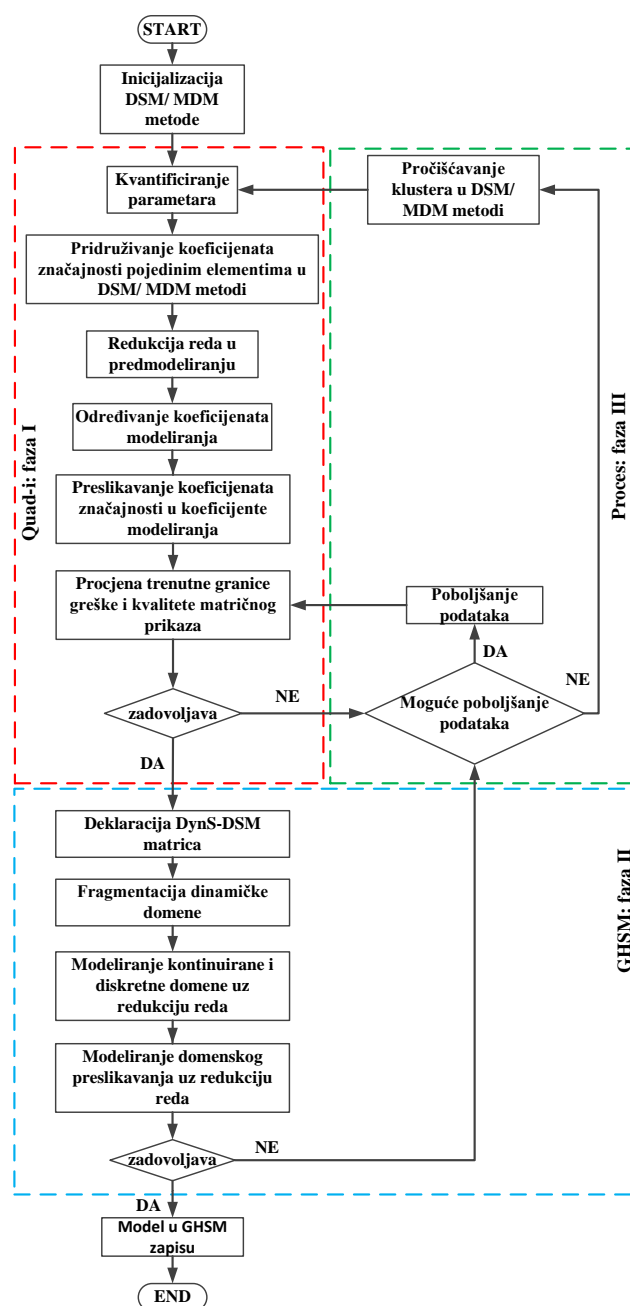
Slika 2.1. Višedomensko preslikavanje u složenom dinamičkom sustavu [7]

Na slici 2.2. prikazan je rezultirajući proces modeliranja sustava u pristupu višedomenskog preslikavanja [7]. Smanjenje indirektnih ovisnosti u sustavu promatra se kroz dio prikupljanja podataka.



Slika 2.2. Modeliranje ponašanja sustava kod višedomenskog preslikavanja [7]

Proces ne prikazuje sve aktivnosti koje su inače prikazane u pristupu menadžmenta složenih struktura, već su one zamijenjene sa fazama modeliranja, simuliranja i interpretacije rezultata. Interpretacija rezultata transformira rezultate dobivene simulacijom i zaključke iz matematičke analize u konkretno i određeno ponašanje sustava. Time se dobiva odgovor na postavljeni inicijalni problem. U pristupu se koriste povratne petlje na model strukture, da bi se dobili prihvatljivi podsustavi za daljnju analizu. Možemo reći da se tim petljama vrši podešavanje strukture sustava [7].



Slika 2.3. Dijagram toka quad-I/HS okruženja ([4], [6], [20])

Kasnije je DynS-DSM pristup proširen na okruženje, koje se zove quad-I/HS (engl. *Interactive Interaction Importance Identification/Hybrid State*) ([4], [6], [20]), koje podržava sustavno modeliranje hibridnih dinamičkih sustava (slika 2.3.).

U tom okruženju koristi se znanje bazirano na grafovima u proceduri modeliranja. Okruženje je podijeljeno u 3 faze i 10 koraka, koje se mogu promatrati odvojeno. Također okruženje podržava kolaborativno modeliranje umreženih sustava ([4], [6]).

2.2. Neizvjesnost u konstruiranju


Jedna od čestih definicija neizvjesnosti (engl. *Uncertainty*) potječe od Hubbarda [39], definira neizvjesnost kao stanje ograničenog znanja kada nije moguće s dovoljnom točnosti opisati postojeće stanje, budući ishod ili više mogućih ishoda. Značenje pojma neizvjesnosti se u literaturi različito tumači ovisno o kontekstu, tj. znanstvenom području u kojem se ovaj pojam razmatra. Pritom se u pojedinim područjima znanosti definicija pojma i klasifikacija tipova neizvjesnosti usko vezuje samo uz neizvjesnosti koje su od primarnog značaja za ta područja.

Iz tog razloga u literaturi ne postoji jedinstvena i sveobuhvatna definicija pojma neizvjesnosti koja bi bila valjana bez obzira o kontekstu u kojem se razmatra.

Uzroci neizvjesnosti mogu se klasificirati u dvije skupine, (slika 2.4.): nedostatak znanja i nedostatak definicije [40]. Ograničeno znanje (nedostatak znanja) javlja se u slučajevima kada nisu dostupne potrebne informacije. Nedostatak znanja može se dalje klasificirati kao kvantitativni i kvalitativni [41]. Kvantitativni nedostatak znanja možemo prepoznati u onim slučajevima kada donositelj odluka nema informaciju o izvršenim stanjima sustava, dok kvalitativni nedostatak javlja kada imamo potrebnu informaciju. No ta informacija ne može deterministički opisati situaciju.

Drugi uzrok neizvjesnosti je nedostatak definicije, koji potječe od nepreciznosti [42]. To se pojavljuje kod sustava koji još nisu određeni ili definirani, npr. pri razvoju novih proizvoda.

Uzrok koji to također može prouzročiti je obilje informacija koje je nastalo zbog ograničene sposobnosti ljudskog bića da opaža i procesira te zbog dvosmislenosti izraza, tj. onih koji imaju dvosmisleno značenje [43]. Nedostatak definicije može nastati i uslijed proturječnih dokaza koji opisuju različite informacije o ponašanju sustava i uvjerenja pritom da su svi dokazi subjektivni [44].




Slika 2.4. Klasifikacija uzroka neizvjesnosti [40]

Prema *Kreye i ostali* [45], attribute neizvjesnosti možemo holistički klasificirati u 5 podjela (vidi tablicu 2.1.). *Walker i ostali* [46] predlažu da se događanje neizvjesnosti može promatrati kroz pet aspekata: kontekst, ulazi, parametri modela i ishod (prikazano na slici 2.5.). Definicije sa svojim značenjima, te zbog svog opisa koji su dani u drugim pristupima sadrže mnogo preklapanja.

Tablica 2.1. Atributi neizvjesnosti [26]

Atributi	Opis	Literatura
<i>Karakter</i>	Opća karakteristika neizvjesnosti. Javlja se u slučajevima ako se radi o svojstvenoj varijabilnosti (aleatorska neizvjesnost) ili općeg nedostatka znanja (epistemička neizvjesnost).	[47] - [49]
<i>Uzrok</i>	Razlog uzroka neizvjesnosti. Neizvjesnost općenito može biti uzrokovana nedostatkom razumijevanja, nejasnoćom i ljudskim ponašanjem, s različitim potkategorijama unutar svakog od ova tri uzroka.	[50] - [52]
<i>Nivo</i>	Težina neizvjesnosti, odnosno količina dostupnih informacija ili količina informacija koja nedostaje za određeni opis situacije.	[53], [54]
<i>Događanje</i>	Točka procesa u kojoj se neizvjesnost javlja.	[41], [46]
<i>Izražavanje</i>	Neizvjesnost je artikulirana ili priopćena, pritom to može biti kvantitativno (mjerljivo), odnosno kvalitativno (nemjerljivo).	[47], [55], [56]



Slika 2.5. Osnovne vrste neizvjesnosti [46]

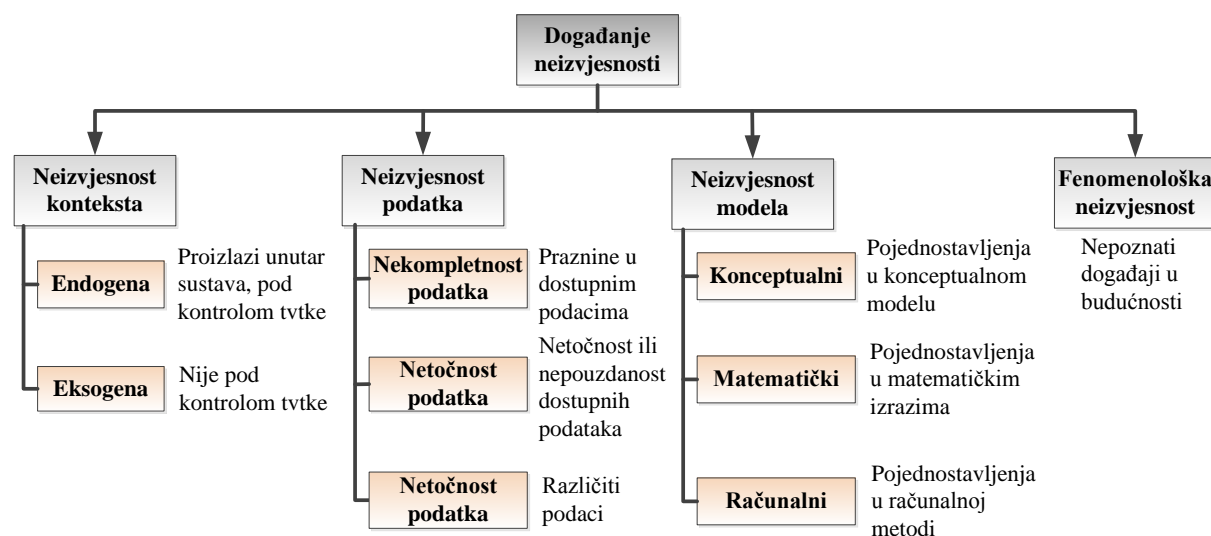
Nadalje, klasifikacija, koju predlaže *Walker i ostali* [46], ne uzima u obzir neizvjesnost koja je povezana s budućim događajima kao što su implikacije koje će današnja odluka imati na buduće mogućnosti ili na tijek životnog ciklusa proizvoda te njihov utjecaj u fazi razvoja proizvoda [4]. Napominje se da autori ne uzimaju u obzir neizvjesnost koja može imati dugoročne posljedice, kao što su točnost procjene ili prognoze na razvijeni proizvod.

Osnovne vrste neizvjesnosti (prikazano na slici 2.5.) dijele se prema [46]:

- *kontekstu situacije problema* koji se manifestira u kontekstu neizvjesnosti,
- *ulazu u proces* (kao što su parametri konstrukcije) koji se manifestira u neizvjesnosti podatka,
- *modelu strukture* sa svojim parametrima koji se manifestira u modelu neizvjesnosti,
- *izlazu iz modeliranog procesa* (performanse) koji se manifestira u fenomenološku neizvjesnost.


Prema *Kreye i ostali* [45], dana je slijedeća klasifikacija osnovnih vrsti neizvjesnosti, prikazana na slici 2.6. Kada govorimo o vrsti neizvjesnosti koja se manifestira kroz model strukture, u literaturi se navodi prikladniji naziv neodređenost. Kad opet govorimo o vrsti koja se manifestira na ulazu i izlazu iz procesa (neizvjesnost podatka, odnosno fenomenološka neizvjesnost), prikladniji naziv bio bi nesigurnost.

Prema *Knetsch* [57] postoje različiti modeli neizvjesnosti prema vrsti informacije [58] pomoću kojih ih se može klasificirati. Prema tome predlaže podjelu neizvjesnosti na tri skupine: *aleatorsku*, *epistemičku* i *prognoziranu* (prikazano na slici 2.7.).



Slika 2.6. Klasifikacija osnovnih vrsti neizvjesnosti [45]

Epistemička nesigurnost uzrokovana je nedovoljnom informiranosti o proizvodu ili procesu. Zbog nedostatka znanja stvarnost se ogleda nepotpuno, manjkavo, a ne dovoljno eksplicitno. Obuhvaća apstraktne, privremene i nepotpune modele proizvoda. Ova vrsta neizvjesnosti može se pojaviti u virtualnom procesu razvoja proizvoda.



Slika 2.7. Podjela neizvjesnosti prema vrsti informacije [57]

Prognozirana nesigurnost će postojati ako se karakteristike proizvoda i procesa u budućnosti moraju mjeriti. Javlja se recimo kod prognoze neizvjesnosti po pogledu životnog ciklusa proizvoda te u slučajevima kad se uslijed potreba kupaca traže promjene tijekom procesa razvoja ili tijekom očekivanog korisnog vijeka trajanja proizvoda. To se recimo može ostvariti kroz posebne metode prognoze kojima je moguće predvidjeti buduća svojstva proizvoda.

Prema projektu SFB 805 „Control of Uncertainty in Load Carrying Structures in Mechanical Engineering“ [60], provedenom na fakultetu TU Darmstadt u Njemačkoj, te radu od Engelhardt i ostali [61], modeli neizvjesnosti su podijeljeni u tri kategorije prema rastućem stanju informacije o razdiobi vjerojatnosti vrijednosti u neizvjesnim proizvodima: *nepoznata*, *estimirana* i *stohastička* neizvjesnost (prikazano na slici 2.8.). Enumeracija klasifikacije provedena je prema stupnju povećanja informacije.

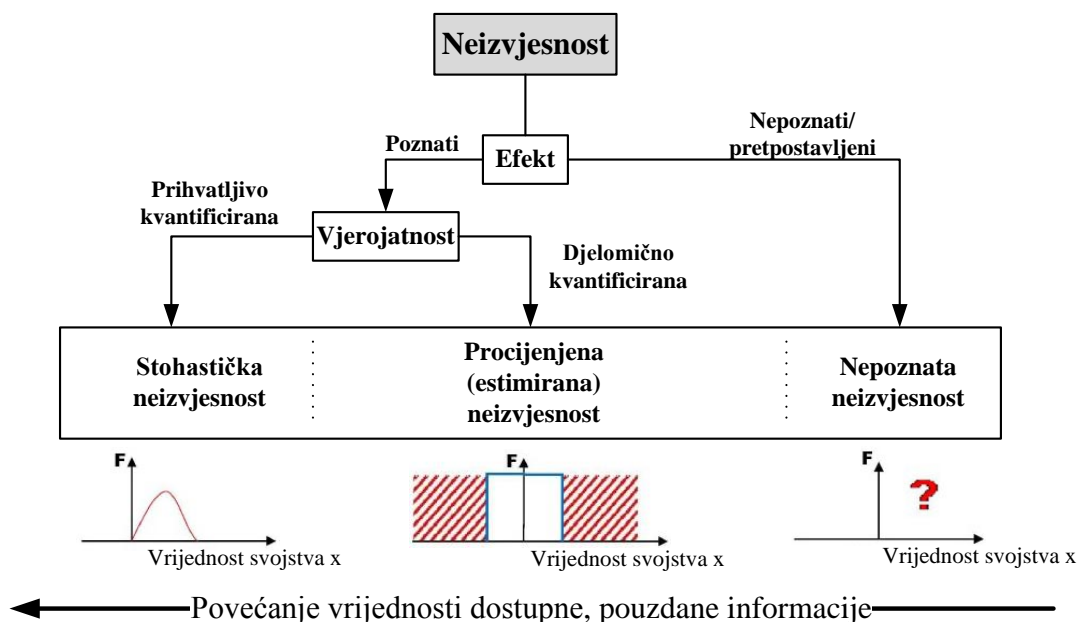
Nepoznata neizvjesnost (engl. *Unknown uncertainty*) ([60], [61]) opisuje situaciju nepoznatih odstupanja od promatranih svojstva u neizvjesnom procesu.

Na temelju takvog stanja informacija, nikakve sveobuhvatne odluke nije moguće donijeti u pogledu kontrole neizvjesnosti. Ona se često javlja u početku razvoja proizvoda, kada je vrlo malo informacija poznato o budućem proizvodu i svojstva mu još nisu određena.

Procijenjena (estimirana) neizvjesnost (engl. *Estimated uncertainty*) ([60], [61]), opisuje situaciju u kojoj su efekti promatranog svojstva proizvoda poznati. Međutim, distribucija vjerojatnosti od rezultirajućeg odstupanja je samo djelomično poznata. To je primjerice slučaj kada imamo nepotpune informacije o očekivanim svojstvima proizvoda koji je poznat tijekom razvoja proizvoda ili ako se, tijekom proizvodnje, nasumično analiziraju njegova svojstva.

Stohastička neizvjesnost (engl. *Stochastic uncertainty*) ([60], [61]) javlja se kada su efekti i nastale devijacije promatranog svojstva dostatni (idealno kompletni), te opisani distribucijom vjerojatnosti. Stohastička neizvjesnost je prisutna nakon opsežne analize svojstava u smislu mjerljivih pokusa i mjerenja.

Kada pravimo razliku između ove tri kategorije, među njima nema nekih oštih granica koje se mogu povući. Prijelaz između kategorija je otvoren, tj. možemo reći protočan. Kao opće pravilo, može se reći da neizvjesnost teži prema stohastičkoj, ako se iznos raspoloživih i sigurnih informacija povećava (prikazano na slici 2.8.).



Slika 2.8. Kategorije modela neizvjesnosti ([60], [61])

Za uspješno upravljanje neizvjesnošću i nalaženje robusnog rješenja, potrebno je sustavno odabrati i koristiti metode, kako pojedinačno, tako i u kombinaciji. No, prije svega neizvjesnost se mora otkriti i okarakterizirati unaprijed, kako bi se znalo koje metode se mogu primijeniti. No usprkos svega odabir pojedinačne metode, kao i njihove kombinacije nije uvijek zadovoljavajuća, jer u većini slučajeva navedene metode imaju ograničene mogućnosti korištenja.

Za klasifikaciju metoda za upravljanje neizvjesnošću, u obzir je potrebno uzeti *dva temeljna aspekta* [62]:

- ovisno o razini informacija prema kategorizaciji modela neizvjesnosti, neizvjesnost se može pojaviti vrlo različito,
- upravljanje neizvjesnošću je vrlo složen problem koji se mora riješiti na strukturirani način.

Stoga možemo reći da prema ta dva temeljna aspekta, uspješna klasifikacija metoda za upravljanje neizvjesnošću treba uzeti u obzir: stupanj neizvjesnosti (engl. *Degree of uncertainty*) i fazu procesa u kojoj treba upravljati neizvjesnošću (engl. *Phase in the process to control uncertainty*).

Na slici 2.9. prikazana je podjela metoda prema stupnju neizvjesnosti. Metode su podijeljene horizontalno prema stupnju neizvjesnosti (prema modelima nesigurnosti) u tri kategorije ([60], [62]): nepoznata, procijenjena i stohastička neizvjesnost (prikazano na slici 2.9.).

Stohastička neizvjesnost	Procijenjena (estimirana) neizvjesnost	Nepoznata neizvjesnost
	vizualizacija	brainstorming
	procesni modeli	
mjerenje		istraživanje/ benchmark
	filtrirana informacija	
	matematički modeli	
analiza osjetljivosti		kvalitativne evaluacijske metode
	simulacija	
	analiza rizika	
	aktivno upravljanje	katalog rješenja
optimizacija		
.....
	faktor sigurnosti	

Slika 2.9. Klasifikacija metoda prema stupnju neizvjesnosti ([60], [62])

Ovisno o razini znanja o informacijama o neizvjesnosti, koriste se različite metode.

Da bismo riješili klasifikaciju metoda u nekoliko faza upravljanja neizvjesnošću, potrebna je prije svega [62]:

- Potpuna identifikacija i opis neizvjesnosti, što, prema potrebi, obuhvaća i cijeli životni ciklus proizvoda, te konfiguraciju svih uključenih sustava;
- Kako je broj svojstava proizvoda s neizvjesnim parametrima relativno velik, potrebno je izvršiti procjenu nesigurnosti kako bi se odabrala ona koja je mjerodavna za rješavanje te vrste neizvjesnosti;
- Nemoguće je definirati sustav kod koga ne bi trebalo uzeti u obzir neku od neizvjesnosti.

U cilju sveobuhvatnog upravljanja neizvjesnošću, izvršena je podjela metoda u tri glavne skupine: *metode za otkrivanje i opisivanje neizvjesnosti*, *metode za procjenu (evaluaciju) neizvjesnosti* i *metode za projektiranje sustava s neizvjesnim parametrima* ([60], [62]) (prikazano na slici 2.10.).

Metode za otkrivanje i opisivanje neizvjesnosti su metode koje nam daju informacije kako analizirati neizvjesnost ili opisati modele. Tako opisani modeli koriste se kao temelj kod sljedećih metoda upravljanja neizvjesnošću: metoda za opisivanje neizvjesnosti i metoda za projektiranje sustava s neizvjesnim parametrima ([60], [62]).

			Stohastička neizvjesnost	Procijenjena (estimirana) neizvjesnost	Nepoznata neizvjesnost
Metode za upravljanje neizvjesnošću	Metode za opisivanje neizvjesnosti	Ciljno+ dobiveno stanje	vizualizacija procesni modeli brainstorming		
		Okolina Utjecajne varijable	mjerjenje filtrirana informacija istraživanje/ benchmark		
		Povezivanje modela	matematički modeli		
	Metode za evaluaciju neizvjesnosti	Ponašanje sustava	simulacija analiza osjetljivosti kvalitativne evaluacijske metode		
		Interakcija sa okolinom	analiza rizika		
	Metode za projektiranje sustava s neizvjesnim parametrima	Poništenje/ eliminacija	faktor sigurnosti		
		Adaptacija	aktivno upravljanje optimizacija familije proizvoda		

Slika 2.10. Tablični prikaz nekih metoda za upravljanje neizvjesnošću ([60], [62])

Metode za opisivanje neizvjesnosti se mogu podijeliti prema modelu tehničkih procesa, te tako razlikujemo tri načelna slučaja ([60], [62]):

- neizvjesnost koja nastaje zbog čestih promjena u konačnom stanju procesa,
- neizvjesnost koja nastaje zbog utjecaja okoline na sustav,
- neizvjesnost kao posljedica unutarnje povezanosti sustava.

Prve dvije skupine metoda za opisivanje neizvjesnosti (prema tablici 2.10.), koje opisuju utjecaj okoline i konačno stanje procesa spadaju u skupinu deskriptivnih metoda [62]. Kao što se može vidjeti još postoje i metode koje opisuju utjecajne varijable (npr. poremećajne varijable, informacije) i metode koje služe za opis modela povezanosti (opisuju unutrašnje parametre procesa i matematičke relacije u promatranom sustavu).

Metode za procjenu (evaluaciju) neizvjesnosti ([60], [62]), uključuje metode za pronalaženje prioritete neizvjesnosti i utvrđivanje je li njihov učinak kritičan ili nije. Ove metode mogu razjasniti utjecaj efekata iz kojih proizlazi nesigurnost u procesima. Simulacijske metode za ocjenu sustava i njegovog utjecaja ili metode vrednovanja rizika (koje uključuju okolinu), svrstavaju se u ovu skupinu metoda. Te se metode koriste kao osnova za rješavanje problema kojima možemo pronaći optimalan sustav s neizvjesnim parametrima.

Ove metode mogu se podijeliti u dvije kategorije. U prvoj kategoriji, procjenjuju se matematičke relacije proizvoda i procesa. Ova procjena zanemaruje vanjske utjecaje i posljedice. Druga kategorija sadrži metode koje uključuju interakciju proizvoda i okoline. To su npr. metode kao što su procjene rizika ili analize pouzdanosti. Definirane su ciljne vrijednosti koje se koriste za procjenu i vrednovanje kriterija. Radi se pojedinačna procjena u svrhu provjere jesu li učinci neizvjesnosti kritični ili nisu.

Metode koje se koriste pri projektiranju sustava s neizvjesnim parametrima ([60], [62]). ocjenjuju stupanj otpornosti sustava na neizvjesne utjecaje. Metode su usredotočene na izbjegavanje ili uklanjanje neizvjesnosti u procesima ili na prilagodbi sustava na već postojeće neizvjesnosti, tako da učinci više nisu kritični. Ove metode koriste, na primjer, kataloška rješenja ili metode optimizacije. Kod njih postoje dva općenita pristupa. Jedan od pristupa su metode koje se koriste kako bi se uklonila neizvjesna svojstva. Pritom se koriste informacije koje se pronađu tijekom karakterizacije i procjene kako bi se proces učinio još robusnijim. Pritom se eliminiraju svi nedostaci koji su identificirani kroz proces evaluacije.

Pod drugu opciju spadaju metode koje se koriste za adaptaciju neizvjesnih svojstava procesa. Koriste se informacije dobivene tijekom karakterizacije i ocjenjivanja proizvoda. Primjenjuju se strategije za strukturiranje proizvoda koje ga čine još robusnijim prema neizvjesnosti. Procesi u sustavu se proračunavaju i optimiraju na temelju ulaznih parametara.

2.3. Sustav i složeni sustav

Prema Schneideru, sustav određuju [63]:

- *Struktura* (engl. *Structure*) – sustav se sastoji od određene količine komponenata, koje su međusobno povezane jedne prema drugima, kao i sa okolinom sustava. Sustav je u doticaju sa svojom okolinom putem fizikalnih veličina koje opisuju energiju, masu i stanje informacija sustava,
- *Dekompozicija (razgradnja)* (engl. *Decomposition*) – sustav se sastoji od određene količine komponenata, koje se još mogu dalje dekomponirati u određeni broj podkomponentata koje su također međusobno povezane među sobom. Podkomponente imaju određenu složenost ili opća svojstva promatranog sustava,
- *Uzročnost* (engl. *Causality*) – sustav se sastoji od određene količine komponenata, čiji su međusobni odnosi, kao i vlastite promjene jasno definirane. Slijedeći uzročnu povezanost, kasnija stanja sustava mogu ovisiti jedino o prethodnim stanjima. Kauzalnost se shvaća kao logika događaja,
- *Privremenost* (engl. *Temporarity*) – sustav se sastoji od određene količine komponenata, čija struktura i stanje u većoj ili manjoj mjeri određuju promjene u sustavu koje se javljaju tokom vremena. Privremenost je slijed događaja i promjena tokom vremena.

Wasson definira sustav [64] kao „integrirani skup od interoperativnih entiteta, svaki s eksplicitno specificiranim i ograničenim sposobnostima, koji radi sinergistički rezultirajući novom vrijednosti. Time omogućava korisniku da zadovolji operacijski zadane zahtjeve u propisanom radnom okruženju sa specifičnim izlaznim podacima i vjerojatnošću uspjeha“. Izraz „integrirani skup“ upućuje na činjenicu da se sustav sastoji od „hijerarhijskih nivoa fizikalnih entiteta, entiteta i komponenti“. Entiteti su interoperativni, te moraju biti kompatibilni jedan s drugim da bi postigli „veću vrijednost“ sustava [65].

Termin je još određen i s “eksplicitno specificiranim i ograničenim sposobnostima”, što znači da svaki entitet “mora raditi da bi ostvario neki cilj na višem nivou”. Da bi radio “sinergistički”, ističe dodatnu vrijednost [66], kao i utjecajni faktor mreže. Taj aspekt orijentacije korisnika je dodatno naglašen izrazom “specifični ishod” i “uspjeh” u definiciji prema [67].

Kada govorimo o *složenom sustavu*, možemo reći da je to sustav sastavljen od međusobno povezanih dijelova koji kao cjelina posjeduju jedno ili više svojstava (a time i ponašanje među mogućim svojstvima) koje nije očito iz svojstava pojedinih dijelova [24].

Također možemo reći da je sustav (prema *Rindu* [68]), onaj koji ima više interakcija između različitih komponenti (odnosno podsustava), a njegova obilježja su: posjeduje nelinearne odnose, sadrži povratne petlje, otvoren je, ima pamćenje, njegovi pojedini dijelovi (komponente i podsustavi) također mogu biti složeni, teško mu je utvrditi granice sustava, te može proizvesti razne pojavne fenomene.

U mnogo općenitijem pristupu, *Maurer* [23] daje definiciju složenog sustava koja poklapa *Wassonovoj* definiciji: “Sustav je kreiran pomoću kompatibilnih i međusobno povezanih dijelova koji daju formu strukture sustava, posjeduju pojedinačna svojstva i doprinose tome da zadovolje svrhu sustava. Sustavi su ograničeni granicama sustava i povezani sa svojim okolinama preko ulaznih i izlaznih podataka.

Promjene u dijelovima sustava mogu biti karakterizirane dinamičkim efektima i rezultatom u specifičnom okruženju sustava“.

2.4. Arhitektura proizvoda

Ulrich i Eppinger [69], definirali su arhitekturu proizvoda kao shemu po kojoj su funkcijski elementi proizvoda raspoređeni u fizičke komponente i na temelju koje komponente međusobno djeluju. Preciznija definicija arhitekture proizvoda dana je u radu [8], u smislu da arhitektura sadrži:

1. strukturu funkcija,
2. preslikavanje funkcija u fizičke komponente,
3. specifikaciju sučelja između fizičkih komponenata koje međusobno djeluju.

Prema navedenoj definiciji svaki tehnički proizvod sadrži sve tri karakteristike arhitekture proizvoda.

Za svaki tehnički proizvod može se opisati struktura funkcija, preslikavanje između funkcija i komponenata te definirati sučelja između komponenata. *Lanner* i *Malmqvist* [70], navode da svi proizvodi posjeduju određenu vrstu arhitekture proizvoda bez obzira da li je arhitektura korištena tijekom konstruiranja ili ne.

Ovisno o pridruživanju funkcija komponentama, *Ulrich* [8] razlikuje: integralnu i modularnu arhitekturu proizvoda.

Kod modularne arhitekture je bitno da su jedna ili više određenih funkcija sadržane u jednom modulu, dok je kod integralne arhitekture jedna funkcija sadržana u više elemenata. Takva podjela prikazana je u tablici 2.2. (prema [8]). Korištenje modularne ili integralne arhitekture proizvoda ovisi o različitim zahtjevima koji su postavljeni razvoju familije proizvoda. Za ostvarivanje fleksibilnosti i raznolikosti proizvoda upotrebljava se modularna arhitektura, dok se za postizanje stabilnosti i optimizacije proizvoda upotrebljava integralna arhitektura.

Tablica 2.2. Odnos arhitekture proizvoda o funkcijama proizvoda [8]

1:1	Jedna funkcija realizirana je u jednom elementu	Modularna arhitektura
1:N	Jedna funkcija realizirana je u više elemenata	Integralna arhitektura
N:1	Nekoliko funkcija realizirano je u jednom elementu	Modularna arhitektura
N:M	Nekoliko funkcija realizirano je u više elemenata	Integralna arhitektura

2.5. Dinamički sustavi

U radu [72] *Vukić i Kuljača*, ističu slijedeće karakteristike dinamičkih sustava:

1. *Usmjerenost djelovanja* – kako pojedinačnu komponentu uključujemo u sustav, tako ona postaje „prijemnik“ izlaznih djelovanja jedne komponente ili grupe komponenata, te s druge strane, svojim izlaznim veličinama uspostavlja veze (kažemo da oblikuje ulazna djelovanja) na neku drugu komponentu ili grupu njih;
2. *Kauzalnost sustava* – svi fizikalni sustavi (a time i tehnički sustavi), koji rade u stvarnom vremenu imaju ovo svojstvo. Podrazumijeva se da vrijeme protječe jednoliko i usmjereno, a time se onemogućuje da posljedica bude prije uzroka;
3. *Ograničenost energetske resursa* – kažemo da svaki tehnički sustav ima ograničeni broj, a time i kapacitet skladišta energije;
4. *Ograničenost informacijskog kapaciteta* – kažemo da svaki tehnički sustav može podnijeti ograničenu količinu informacija, koju je u stanju obraditi, te njome ostvariti željeni cilj;

5. *Strukturiranost* – znači da je tehnički sustav koncipiran kao strukturirani objekt, koji sadrži ulaze (pobude) i izlaze (odzive). Oni pripadaju ograničenoj i potpuno određenoj klasi funkcija koje djeluju u zadanom vremenskom intervalu. Ulazi i izlazi mogu biti: tvari, energija i informacije;

6. *Povezanost procesa unutar sustava* – procesi koji se odvijaju unutar sustava povezani su i ne djeluju izolirano, funkcije su vremena, a mogu biti kontinuirani ili diskretni.

Prema Šermanu [73] dinamički sustav je onaj „čije trenutno stanje ne ovisi samo o trenutnom djelovanju okoline, već i o njegovom prethodnom stanju“. U tu skupinu mogu se ubrojiti svi realni fizikalni sustavi, ali se time mogu smatrati i neke druge cjeline koje promatrač izdvaja iz njegove okoline.

Suvremena teorija sustava izgrađena je oko *koncepta stanja dinamičkih sustava* [72], koji je prisutan u svim sustavima i predstavlja njenu središnju varijablu. Stanje sustava predstavlja ukupno znanje o njegovom statusu u određenom vremenskom trenutku. To znanje nam govori da poznamo stanje sustava u nekom početnom trenutku t_0 , kao i same pobuda koje djeluju na sustav nakon tog trenutka. To nam omogućuje da odredimo stanje dinamičkog sustava u nekom drugom trenutku t_1 ($t_1 > t_0$). U bilo kojem trenutku stanje dinamičkog sustava moguće je opisati skupom varijabli x_i , koje se zovu *varijable stanja* ([72], [74]).

U literaturi postoje različita svrstavanja dinamičkih sustava. Sažeti pregled dan je prema ([72] - [75]), u nastavku:

a) *Linearni i nelinearni sustavi* – za linearne sustave vrijede *svojstva aditivnosti i homogenosti*. Ako udovoljava tome, kažemo da zadovoljava *načelo superpozicije*. Za razliku od njih kod nelinearnih sustava, njihovo dinamičko stanje ne može se opisati linearnim operatorom. Za takve sustave nije razrađena opća teorija rješavanja nelinearnih diferencijalnih jednadžbi, pa se dinamička analiza provodi približnim postupcima [76].

b) *Sustavi s koncentriranim i raspodijeljenim (distribuiranim) parametrima* – kod sustava s koncentriranim parametrima, stanje procesa u pojedinačnoj komponenti elementu (komponenti) sustava u svakom trenutku vremena definira se srednjom vrijednosti polja varijabli unutar volumena. Kod takvih sustava postoji konačno mnogo idealiziranih pojedinačnih elemenata.

Kod sustava s raspodijeljenim parametrima, prostor elementa (komponente) sustava promatra se kao skup od beskonačno mnogo infitenzimalnih spremnika, koji su raspodijeljeni po cijelom njegovom volumenu. Njih ćemo koristiti kada će nam za matematički model nekog elementa (komponente) sustava biti bitno da model odražava upravo ona svojstva uzročno-posljedičnih veza između izlaza i ulaza u sustav, koja su uvjetovana poljima varijabli unutar njegovog volumena [73].

c) *Kontinuirani i diskretni sustavi* – kontinuirani sustavi (engl. *Continuous systems*), su oni kod kojih se njihove varijable mijenjaju kontinuirano po vremenu. Opis takvih sustava moguć je diferencijalnim jednadžbama [72]. Diskretni sustavi (engl. *Discrete systems*), su oni koji se prate (odnosno mjere), samo u diskretnim vremenskim trenucima. Opisuju se jednadžbama diferencija, te je kod njih obavljena diskretizacija signala po nekoj karakteristici (vremenu, razini ili nekoj drugoj) ([72], [77]).

d) *Vremenski nepromjenjivi i vremenski promjenjivi sustavi* – vremenski nepromjenjivi (engl. *Time invariant system*) su oni sustavi kod kojih se parametri konstantni tijekom vremena, kod njih se svojstva ne mijenjaju tijekom vremena. Vremenski promjenjivi sustavi (engl. *Time variant systems*) su oni čiji se koeficijenti koji karakteriziraju sustav mijenjaju s vremenom.

e) *Deterministički, nedeterministički i stohastički sustavi* – kod determinističkog sustava nema neizvjesnosti u varijablama ili svojstvima sustava. Nedeterministički sustav je onaj koji se u raznim slučajevima pod jednakim uvjetima, različito ponaša.

Kod stohastičkog sustava, da bi se odredilo njegovo ponašanje, potrebno je pojedinim varijablama ili svojstvima sustava, pridružiti određenu mjeru vjerojatnosti.

f) *Hibridni sustavi* (engl. *Hybrid systems*) – sustavi u kojima su procesi opisani interakcijom kontinuiranih i diskretnih varijabli. Interakcija kontinuiranih i diskretnih varijabli obavlja se u linearnim nejednadžbama (engl. *Mixed integer inequalities - MII*). One se rješavaju posebnim matematičkim aparatima, tzv. matematičkim programima za miješane kontinuirane i diskretne varijable (engl. *Mixed integer programs - MIP*) ([72], [74], [78]).

Podjela se nastojala dati na ovaj način prema redoslijedu pojavljivanja pojedinih definicija u daljem tekstu rada.

2.6. Stabilnost dinamičkih sustava

Za stabilnost se može reći da je temeljno kvalitativno svojstvo bilo kojeg uporabljivog tehničkog sustava [72]. Stoga sustav koji se promatra, mora prije svega biti stabilan. Nakon osiguranja stabilnosti promatranog sustava, mogu se zahtijevati i druga kvalitativna svojstva.

Osnovni zadatak teorije stabilnosti je da donese zaključak o ponašanju sustava (koje je prezentirano trajektorijom stanja), bez rješavanja diferencijalnih jednadžbi. Teorija razmatra ponašanje sustava kroz dulji period vremena, tj. kako se stanje sustava ponaša kad vrijeme $t \rightarrow \infty$.

Bitni napredak u razmatranju stabilnosti sustava, potrebno je zahvaliti ruskom matematičaru *Alekseju Mihailoviču Ljapunovu*, koji je definirao opće koncepte stabilnosti [79], koji vrijede kako za linearne, tako i za nelinearne sustave.

Stabilnost sustava, može se promatrati sa više stajališta, koji se navode u nastavku.

Prije svega, može se promatrati sa ulazno-izlaznog stajališta, kada se traži da se odziv promatranog sustava ponaša „prikladno“ (odnosno „ograničeno“) u nekom smislu, onda kada je i pobuda na sustav „prikladna“ („ograničena“) ([72], [76]).

Uz to može se promatrati i praćenjem asimptotskog ponašanja stanja sustava u okolini ravnotežnih stanja sustava ili periodičkih orbita, odnosno vibracija sustava ([72], [76], [80]). U tom slučaju govori se o stabilnosti u smislu Ljapunova, koji je proučavao stabilnost u okolini ravnotežnog stanja sustava [79].

Općenito se pojam stabilnosti može povezati s njegovom sposobnošću, da se pritom uz određenu točnost, nakon prestanka djelovanja vanjskih sila, vraća u početno ravnotežno stanje ([72], [74], [76], [80]). Nestabilan će se pak sustav, nakon prestanka djelovanja vanjskih sila, sve više udaljavati od početnog ravnotežnog stanja ili će oko njega ostati vibrirati nedopustivo velikim amplitudama.

Pravilno bi bilo govoriti o stabilnosti ne samog sustava, već njegovog stanja – ravnoteže ili gibanja. Jedino u slučaju kad bi sustav posjedovao samo jedno ravnotežno stanje, imalo bi smisla koristiti pojam „stabilnost sustava“, kao što je slučaj kod linearnih sustava. U slučaju nelinearnih sustava [76], kada postoji više ravnotežnih stanja, pravilno je koristiti pojam „stabilnost ravnotežnih stanja“.

Kod nelinearnih sustava, jedino u slučaju kada su sva moguća ravnotežna stanja stabilna, možemo reći da je sustav stabilan. Kod linearnih sustava [72] stabilnost ne ovisi o početnim uvjetima, kao ni o pobudi koja na njega djeluje. Stoga je analiza stabilnosti linearnog sustava mnogo lakša, nego analiza stabilnosti nelinearnih stanja ravnotežnih sustava. Kod nelinearnih sustava vrijedi obrnuto [76], stabilnost ravnotežnih stanja ovisi o početnim uvjetima i pobudi koja djeluje na sustav. Kod njih se zbog jednostavnosti, promatraju tzv. nepobuđeni nelinearni sustavi, čime se olakšava analiza stabilnosti.

2.7. Odlučivanje u konstruiranju

Još od 60-tih godina prošlog stoljeća, odlučivanje u konstruiranju (engl. *Decision Making in Design*) opisano je kao iterativan proces [81], prema *Herbertu Simonu*. Slika 2.11. prikazuje tok tog iterativnog procesa [82].

Odlučivanje (donošenje odluka) u konstruiranju, u širem smislu riječi, podrazumijeva generiranje konstrukcijskih alternativa, analizu dotičnih alternative, putem sheme evaluacije i eventualno odabiranje najprihvatljivije od njih [81].

Bilo koji proces odlučivanja, sastoji se od 3 temeljne faze [81]:

- postavljanje cilja ili ciljeva (ako ih ima više od jednog),
- identifikacija ograničenja,
- identifikacija opcija.

Ključni problem koji se javlja kod istraživanja u području metoda za potporu odlučivanja u konstruiranju [81] je kako među svim danim alternativama odabrati onu najpovoljniju. Da bi sproveli željeni odabir konstruktori moraju znati što žele postići, tj. moraju imati jasno definirane ciljeve u konstruiranju. Uz to moraju biti u mogućnosti evaluirati ili predvidjeti mjere performansi alternativa za ono što oni žele i pritom uzeti u obzir i moguće neizvjesnosti koje se pritom mogu javiti. Imati jasne ciljeve u konstruiranju, nije samo važno da bi se odabrala željena alternativa, već je bitno i za samo poboljšanje sposobnosti konstruktora kod generiranja novih i više relevantnih konstrukcijskih alternativa ([83], [84]).

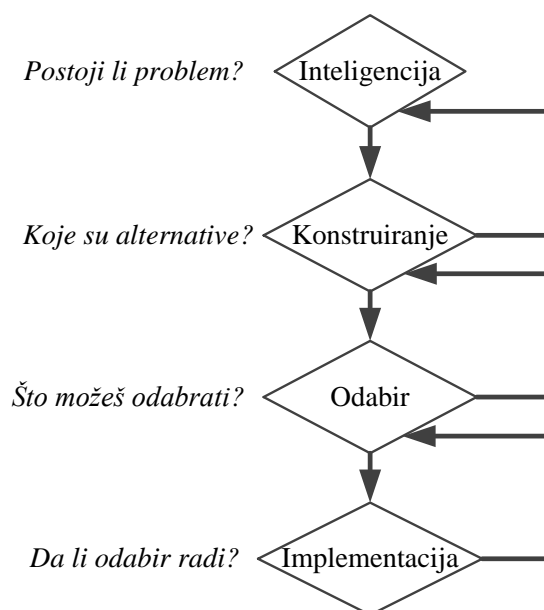
Metode odlučivanja u konstruiranju možemo podijeliti u dvije osnovne skupine: heurističke i teoretske [81].

Prva skupina metoda se za razliku od teoretskih metoda oslanja na osnovne principe heuristike. Smisleni i svrhoviti kriteriji konstruiranja, zajedno sa dobrim procesima konstruiranja mogu poboljšati rezultate konstruiranja. No ipak je malo teoretsko jamstvo da su ti kriteriji u skladu s onim što u biti konstruktor želi i da će se time postići najbolja konstrukcija, posebice kad je u to još uključena i neizvjesnost. Znanstvenicima koji se bave ovim područjem su upravo najinteresantniji takvi tipovi problema ([85], [86]).

Pošto se problem neizvjesnosti često javlja kod donošenja odluka, ishodi kod određenih alternativa ne mogu biti jasno određeni. U donošenju odluka, predložene su razne metode, uključujući i tzv. metode nepreciznosti, tokom rješavanja konstruktorskih pitanja tokom ranih faza u procesu konstruiranja. Kod njih se ne mogu odrediti specifične vrijednosti danih konstruktorskih parametara [87], te se tu susreće i s problemom neizvjesnosti informacija ([88] - [90]).

Uz to postoje i metode koje se baziraju na aksiomatskim okruženjima za potporu konstruiranju [91], a koje slijede *Neumann*-ove i *Morgenstern*-ove pretpostavke [92].

Kod njih je bit procesa odlučivanja stavljen na maksimalno povećanje dobiti tvrtke, gdje se evaluacija bazira na jedinstvenoj ocjeni kriterija. Donošenje odluka u konstruiranju također je povezano i sa optimizacijom konstrukcije, gdje je najbolji izbor ključ u složenom prostoru konstruiranja ([93], [94]).



Slika 2.11. Općeniti proces odlučivanja u konstruiranju [82]

U grupnom odlučivanju u konstruiranju, donošenje odluka ovisi o integraciji podataka i informacija dobivenih od sudionika iz multidisciplinarnih timova, te time doprinosi konačnim rezultatima konstruiranja [95].

2.8. Implikacije na rad

Ovim poglavljem definiralo se područje istraživanja s naglaskom na domensko istraživanje i neizvjesnost u konstruiranju. Naglasak je dan na jedan pravac istraživanja u području razvoja i validacija alternativa arhitektura tehničkih sustava, tzv. domensko preslikavanje. Na taj pravac se nastavlja istraživanje u ovom doktorskom radu i prikazuje ga s jednog drugog gledišta, razvojem novog algoritma. Uz to je prikazano malo detaljnije područje istraživanja u neizvjesnosti u konstruiranju, uz prikaz modela i metoda koje se zadnjih godina razvijaju i primjenjuju u ovom području. S obzirom na fokus istraživanja, obrađeni su još i pojmovi sustava i složenog sustava, arhitekture proizvoda, dinamičkih sustava, stabilnosti dinamičkih sustava i odlučivanja u konstruiranju.

Uz to je dan i kratak pregled istraživanja, vezan uz ova područja. Svi dani pojmovi vežu se uz područje istraživanja na koje je usko vezano i istraživanje provedeno u doktorskom radu. Na ovaj definirani fokus istraživanja vežu se u slijedećem poglavlju i teoretske osnove istraživanja.

TEORETSKE OSNOVE ISTRAŽIVANJA

Poglavljem su obrađene teoretske osnove istraživanja, gdje su ukratko opisane i prikazane metodologije, teorije i modeli koji su bitni za nastavak istraživanja, odnosno definiranje samog doprinosa u doktorskom radu. Naglasak je stavljen na metodologiju konstruiranja mehatroničkih proizvoda (prema VDI 2206) i teoriju područja, na koju se kasnije veže opisivanje arhitekture tehničkih sustava, kao i pristupi modeliranja ponašanja tehničkih sustava (bit će prikazano u sljedećem poglavlju). Uz to prikazan je i kratki teoretski pregled vezan uz matematičko modeliranje dinamičkih sustava, pristupe i vrste modela koji se koriste. Dan je i kratak pregled i opis metode modelskog prediktivnog upravljanja, metoda određivanja stabilnosti sustava po Ljapunovu, te sustava za odlučivanje baziranih na neizrazitoj logici.

3.1. Pristup inženjerstva sustava

Za inženjerstvo sustava (engl. *System Engineering*) možemo reći da je interdisciplinarni pristup (iz više tehničkih disciplina [96]), koji je fokusiran na to kako konstruirati i upravljati složenim inženjerskim projektima tijekom njihovog životnog ciklusa.

Postoji mnogo definicija o tome što je inženjerstvo sustava, no ovdje ćemo navesti jednu od često spominjanih (prema [97]): „Inženjerstvo sustava je robustan pristup konstruiranju, stvaranju i funkcioniranju sustava“.

Jednostavnije rečeno, pristup se sastoji u identifikaciji i kvantifikaciji ciljeva sustava, kreiranju alternativnih koncepata sustava, performansi konstrukcije, odabiru i implementaciji najboljeg konstrukcijskog rješenja, provjeri je li ono dobro napravljeno i integrirano, te procjeni nakon njegove izvedbe tj. koliko ona dobro zadovoljava postavljene ciljeve.

Pristup inženjerstva sustava koristi pristupe modeliranja i simuliranja sustava da bi se potvrdile pretpostavke ili teorije o sustavima, te interakcija među njima [98].

3.2. Metodologija konstruiranja mehatroničkih proizvoda (prema VDI 2206)

Metodologija prikazuje proceduru konstruiranja mehatroničkih sustava koja je podijeljena u 5 faza (prikazano na slici 3.1.) [99], počevši od faze cilja, preko modeliranja, pa sve do završne faze, odnosno analize sustava. Rezultat metodologije je prihvatljivi koncept mehatroničkog sustava, što je osigurano procesima verifikacije i validacije [100].

Sama metodologija može se promatrati kao kontinuirani ciklus preko tzv. *V-modela* [38]. V proceduralni model je model razvoja sustava napravljen tako da pojednostavljuje razumijevanje same složenosti sustava koja je povezana s procesom razvojem proizvoda. U inženjerstvu sustava se koristi za definiranje jedinstvenog pristupa za razvoj proizvoda ili projekta. On grafički predočava životni ciklus razvoja sustava.

Prema metodologiji [99] složeni mehatronički sustavi općenito obuhvaćaju sinergističku integraciju različitih mehatroničkih modula, tj. elemenata ili komponenata sustava, koji su kombinirani tako da tvore grupu i zajedno obavljaju neku određenu funkciju. Budući da ti moduli obuhvaćaju i predstavljaju različite funkcije, to je značajno i za kreiranje proizvoda na principu hijerarhizacije. Osnovna struktura mehatroničkog sustava, može se pritom shvatiti i kao osnovni modul. Još se pritom koriste i metode kao što su modularizacija, particioniranje i integracija [86].

Metodologija u sebi sadržava glavne korake (kao i njihov redoslijed) koje treba provesti unutar okruženja za validaciju sustava. Osnovni koraci prema metodologiji koji se koriste u modelsko baziranom konstruiranju sustava su [99]:

1. Cilj – utvrđuju se i propisuju istraživački ciljevi i zadaci, da bi se mogle odabrati prikladne metode za modeliranje sustava,

2. Modeliranje - kvaliteta modela je odlučujuća za kvalitetu rezultata analize. Tražena kvaliteta modela bitno ovisi o vrsti samog problema koji se razmatra. Stoga sama točnost prikaza modela ovisi o određenim fizikalnim efektima, kako bi se ponašanje sustava moglo opisati s dovoljnom točnošću. Zamjenski modeli sustava ovise o različitim razinama apstrakcije [99]:

- *Topološki model* – prvo se modelira topologija simuliranog sustava. Ona opisuje raspored i veze elemenata koji obavljaju funkcije (npr. elemenata, podsklopova ili modula). Element općenito prikazuje tri glavne funkcije: kinematičku funkciju (npr. broj kinematičkih veza, duljinu kraka ili položaj zglobova mehaničkog sustava itd.), dinamičku funkciju (npr. kretanje masa pod utjecajem sila i momenata itd.) i mehatroničku funkciju (npr. upravljanje, praćenje, planiranje puta itd.). Topologija mehaničkih elemenata npr. bitno utječe na kinematiku mehatroničkog sustava, stoga, ti se elementi moraju u potpunosti uzeti u obzir u simulacijskom modelu;

- *Fizikalni model* – kreira se na osnovu topološkog opisa. Ovakva prezentacija je definirana adaptiranim varijablama sustava, kao što su npr. masa i duljina u slučaju mehaničkih sustava. Također se propisuju i broj i povezanost krutih tijela, definicija fleksibilnih tijela, trenja i zračnosti ili distribucije masa. Fizikalni model opisuje svojstva sustava u domenskom obliku;

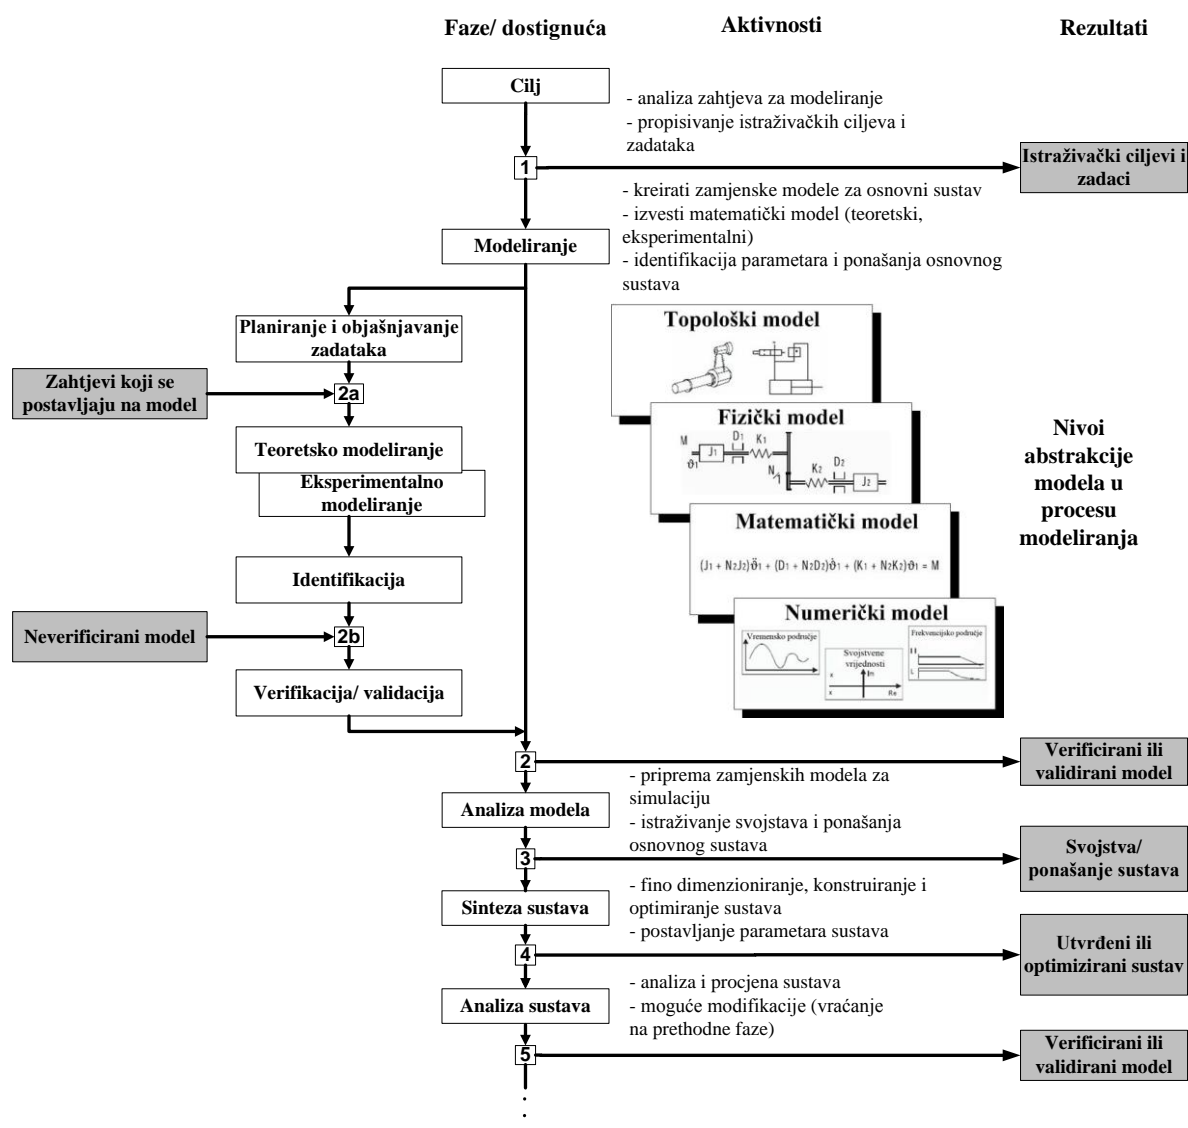
- *Matematički model* – čini osnovu ponašanja sustava. Bazirano na prethodno kreiranom fizičkom modelu, matematički se opisuju fizikalna svojstva sustavu. Matematički model integrira različite domene prezentacije sustava;

- *Numerički model* – predstavlja algoritam baziran na matematičkom modelu sustava. Na osnovu danog algoritma, provodi se simulacija ponašanja sustava. Numerički model ovisi o točnosti i složenosti matematičkog modela, primijenjenoj metodi rješavanja (pogotovo u slučaju nelinearnosti). Numerički model se prikazuje sa konkretnim numeričkim (parametriziranim) vrijednostima. Te vrijednosti su ponekad određene i eksperimentalnom analizom sustava.

3. Analiza modela – na temelju dobivenog modela istražuju se osnovna svojstva promatranog sustava (npr. čvrstoća, korištenjem metode konačnih elemenata, odnosno kinematika i dinamika, korištenjem principa simulacije pomoću dinamike složenih mehaničkih sustava). Analiza daje podatke koji će se koristiti u slijedećoj fazi procedure, sintezi sustava.

4. Sinteza sustava – na temelju simulacija i rezultata iz modela, sustav (njegovi elementi) se fino dimenzioniraju, odnosno optimiraju. Zahtjevi za sintezu sustava proizlaze iz prethodne faze. Sinteza i optimiranje sustava se trebaju provesti u cijelosti. Ako se razmatra nova ili djelomično nova (poboljšana) konstrukcija, konstruktor će propisati konačne parametre sustava za ovu fazu.

5. Analiza sustava – propisani ili optimirani sustav se tada još jednom analizira i ocjenjuje. Pošto se radi o iterativnom procesu moguće je da će se on morati ponavljati kroz više koraka, vraćajući se na prethodne korake u proceduri. Takav proces iterativnog karaktera je vrlo učinkovit jer parametri cjelokupnog sustava konvergiraju prema optimalnom rješenju. O tome umnogome ovisi i sam izbor modela sustava.

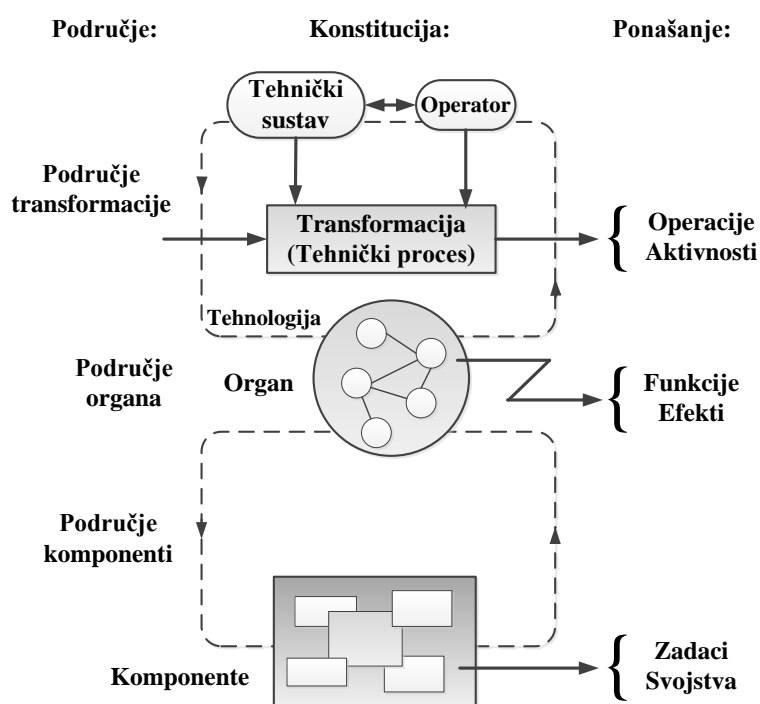


Slika 3.1. Metodologija konstruiranja mehatroničkih proizvoda (prema VDI 2206) [99]

3.3. Teorija područja

Prema Teoriji tehničkih sustava (engl. *Theory of Technical Systems – TTS*) ([10], [11]), nastala je u 80-im godinama prošlog stoljeća *Teorija područja* (engl. *Theory of Domain*), prema *Andreasenu* [14]. Osnovna ideja teorije je da se objasni sinteza tehničkog proizvoda njegovim promatranjem kao sustava s tri gledišta: kroz područje transformacije, područje organa i područje komponenti (prikazano na slici 3.2.). Ta tri pogleda prema teoriji područja obuhvaćaju strukturnu i ponašajnu definiciju tehničkoga proizvoda u skladu s njegovim teoretskim osnovama te se u nastavku ukratko opisuju.

Područje transformacije – u njemu se međusobnom interakcijom tehničkog sustava i čovjeka isporučuju nužni efekti koji su potrebni za transformaciju operanda sa stanjem na ulazu u operande sa stanjem na izlazu. Korake u transformaciji nazivamo operacijama, tijekom kojih dolazi do promjene jednog ili više svojstava operanda.



Slika 3.2. Teorija područja [14]

Područje organa – područje u kojem se modeliraju aktivni elementi tehničkog sustava, tzv. organi. Djelovanje organa temeljeno je na osnovnim fizikalnim i tehničkim principima.

Organ se sastoji od radnih elemenata koji međusobnim djelovanjem stvaraju efekte. Prema Teoriji područja, funkcije tehničkog sustava razmatraju se kao ponašanje organa.

Područje komponenata –područje s težištem na razmještanje organa u komponente koje se mogu fizički proizvesti i sklopiti. Pri tome svaka komponenta prilikom uporabe rješava svoj dio u ukupnom zadatku tehničkog proizvoda. Struktura područja komponenata sastoji se od nerastavljivih komponenata i sklopova pri čemu svaka komponenta ima oblik, izmjere i hrapavost površine.

3.4. Matematičko modeliranje dinamičkih sustava

Matematički model je opis sustava pomoću matematičkih pojmova i jezika. Proces razvoja matematičkog modela se naziva matematičko modeliranje. Matematičkim modelom izražava se ponašanje procesa u sustavu [101].

Matematički model pritom može biti: *nestacionarni* i *stacionarni*. U literaturi je uobičajeno za nestacionarni model, govoriti da je dinamički. Stoga su i svi dinamički sustavi o čijem modeliranju se govori u ovoj točki i u doktorskom radu nestacionarni sustavi.

Veliki dio stvarnih fizikalnih dinamičkih sustava koji poznajemo, ponaša se pod određenim uvjetima, upravo poput linearnog sustava. Možemo reći da se pod takvim uvjetima izvorni nelinearni model takvog sustava može zadovoljavajuće dobro aproksimirati približnim linearnim modelom ([72], [73]).

U radu se bazira na sustave kojima su koeficijenti u njihovim linearnim modelima konstantni, odnosno radi se s *vremenski invarijantnim sustavima* [102]. Linearni modeli takvih sustava imaju oblik *običnih linearnih diferencijalnih jednadžbi s konstantnim koeficijentima*.

Ovisnosti izlaza o ulazima u fizikalnim se dinamičkim sustavima uspostavljaju djelovanjem fizikalnih zakona. Fizikalne (i/ili kemijske) zakonitosti u procesima, zasnivaju se na *općem principu konzervacije (održanja ravnoteže)*, kao temeljnom principu opstojnosti [101].

Iz općeg principa konzervacije slijede jednadžbe koje se koriste u modeliranju dinamičkih sustava, a to su: jednadžba ravnoteže ukupne mase (bilanca ukupne mase), jednadžba ravnoteže komponenata mase (bilanca komponenata) i jednadžba ravnoteže ukupne energije (bilanca energije).

Postupak modeliranja fizikalnih dinamičkih sustava teoretskim pristupom, obuhvaća prema ([33], [73], [101]):

- dobro proučiti procese u sustavu, tj. spoznati njihove fizikalne i kemijske zakonitosti djelovanja,

- odabrati pretpostavke i aproksimacije, koje će rezultirati što jednostavnijim, ali još uvijek dovoljno točnim modelom s obzirom na svrhu modeliranja,
- razlaganje sustava (dekompozicija) na elementarne komponente u skladu s polaznim pretpostavkama i aproksimacijama,
- matematičko formuliranje fizikalnih zakona koji određuju uzročne veze između ulaza i izlaza elementarnih komponenata, te matematičko formuliranje interakcija između njih.

Bitno je spomenuti i polazne pretpostavke, koje se koriste u modeliranju dinamike procesa [73]:

- uzročne veze između uzroka i posljedica su determinističke, tj. kaže se da isti uzroci uvijek izazivaju iste posljedice,
- tvari imaju svojstvo kontinuuma, tj. da oni svoja fizikalna svojstva zadržavaju i unutar infitenzimalno malog volumena.

Osim svih ovih navedenih pretpostavki (koje se najčešće podrazumijevaju i posebno se ne ističu), za svaki pojedinačnom slučaju, uvodi se i niz drugih pretpostavki i aproksimacija. Njima se ostvaruje kompromis između točnosti i složenosti modela. Drugim riječima može se reći da se modeliranje dinamike stvarnih fizikalnih sustava temelji na različitim „idealizacijama fizikalne realnosti“ u pojedinim komponentama promatranog sustava [73].

Važno je napomenuti da svi procesi u elementima (komponentama) fizikalnih dinamičkih sustava u stvarnosti imaju obilježja sustava s raspodijeljenim (distribuiranim) parametrima. Međutim, oblik takvih matematičkih modela sustava (parcijalne diferencijalne jednačbe), u mnogome značajno otežava njihovu primjenu (npr. u analizi problema automatskog upravljanja). Njih ćemo naravno koristiti ako želimo dobiti što točniji, odnosno precizniji model procesa, a i u slučaju kada koristimo zahtjevniji model upravljanja (kao npr. kod optimalnog upravljanja). Kod idealizacija fizikalne realnosti razmatraju se dvije kategorije: idealizacije s obzirom na definiranje spremnika u volumenu definirane komponente i idealizacija s obzirom na svojstvo linearnosti modela [73].

Do matematičkog modela procesa, može se doći na dva načina (prikazano na slici 3.3.) ([101], [103]):

- teoretskim pristupom („*a priori*“ model),
- eksperimentalnim pristupom – identifikacijom procesa („*a posteriori*“ model).

Teoretski pristup ima neke svoje prednosti i nedostatke, pa ih u nastavku navodimo. Prema [103] prednosti teoretskog pristupa su:

- tijekom planiranja i projektiranja procesa i sustava automatizacije realni proces ne mora postojati;
- dobivena rješenja su pritom općenito valjana za slične klase procesa (koji koriste druge dimenzije varijabli i parametara);
- daje dobar uvid u unutarnje odnose u procesu (ovisnosti i odnosi među varijablama stanja).

Teoretski pristup ima i neke nedostatke, prema [103]:

- složeni matematički modeli često su neprikladni za daljnje primjene (npr. za simulaciju sustava upravljanja ili projektiranje regulatora),
- nesigurno je određivanje parametara procesa i vanjskih poremećajnih djelovanja.

U praksi se daje prednost eksperimentalnom pristupu određivanja matematičkog modela, dok se model dobiven teoretskom analizom koristi za procjenu (estimaciju) strukture modela. Uz rezultate teoretske analize, kod eksperimentalnog pristupa, koriste se i podaci dobiveni pomoću mjerenja.

Prednosti eksperimentalnog pristupa su prema [103]:

- -za promatrani proces nisu potrebna detaljna specijalistička znanja,
- -pristupom dobivamo jednostavnije matematičke modele koji zadovoljavajuće dobro opisuju proces.

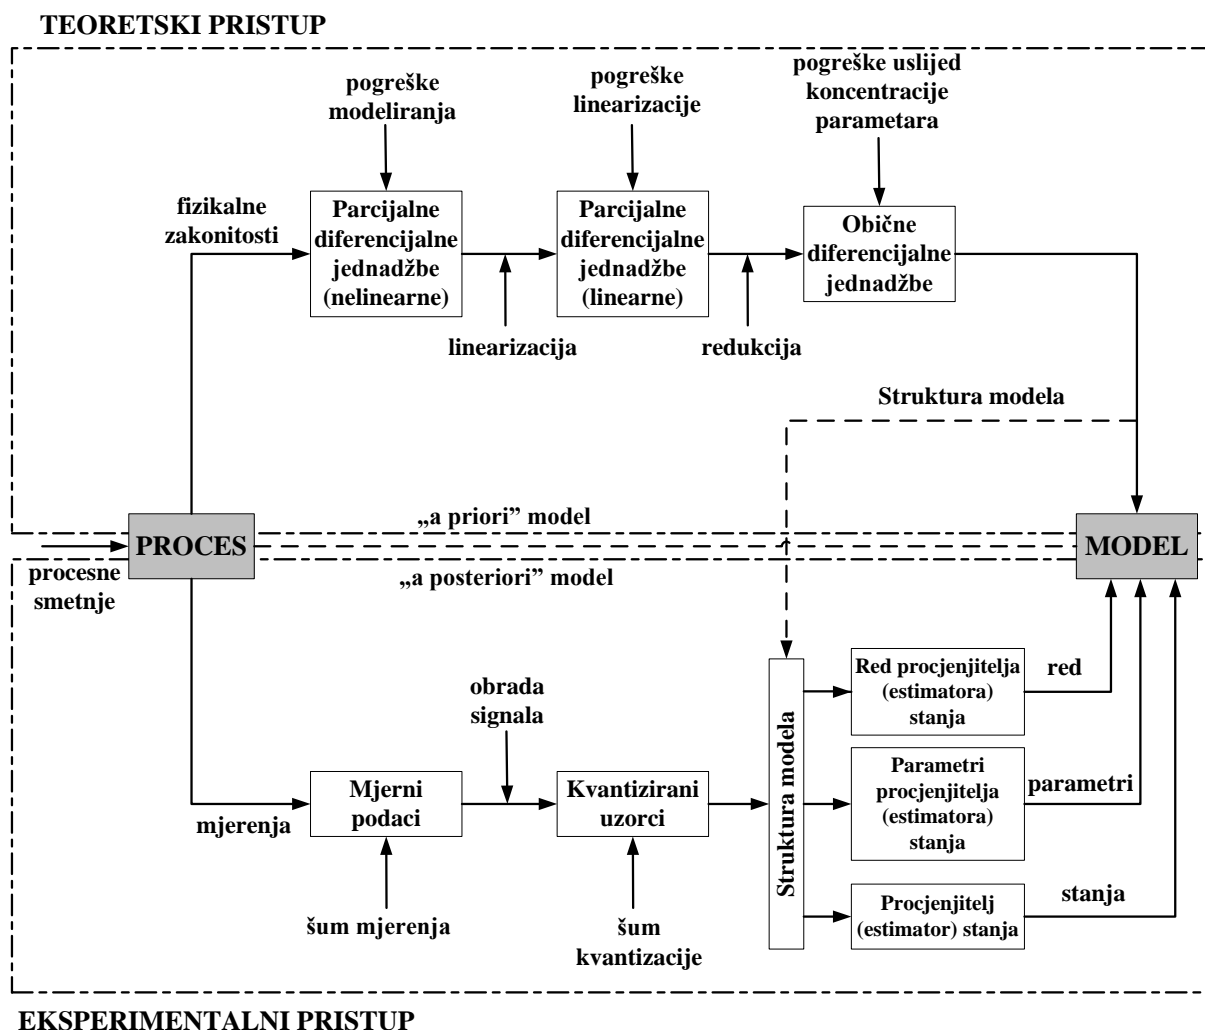
Nedostaci eksperimentalnog pristupa su [103]:

- mora postojati promatrani (istraživani) proces,
- dobiveni rezultati ograničeno su primjenljivi samo na slične procese.

Zbog svega toga kažemo da je analiza procesa općenito iterativni postupak kombiniranja teoretske i eksperimentalne analize ([101], [103]).

U razvoju mehatroničkih sustava, koriste se različiti tipovi modela, što je prikazano njihovom hijerarhijom (vidi sliku 3.4.) [104].

Svaka perspektiva opisuje različita svojstva istog mehatroničkog sustava. Tako razlikujemo kvalitativne i kvantitativne modele mehatroničkih sustava.



Slika 3.3. Prikaz teoretskog i eksperimentalnog pristupa u kreiranju matematičkog modela sustava [101]

Kod kvalitativnih modela, sustav se može opisati koristeći isključivo kvalitativne atribute, što rezultira kvalitativnim modelom sustava [104].

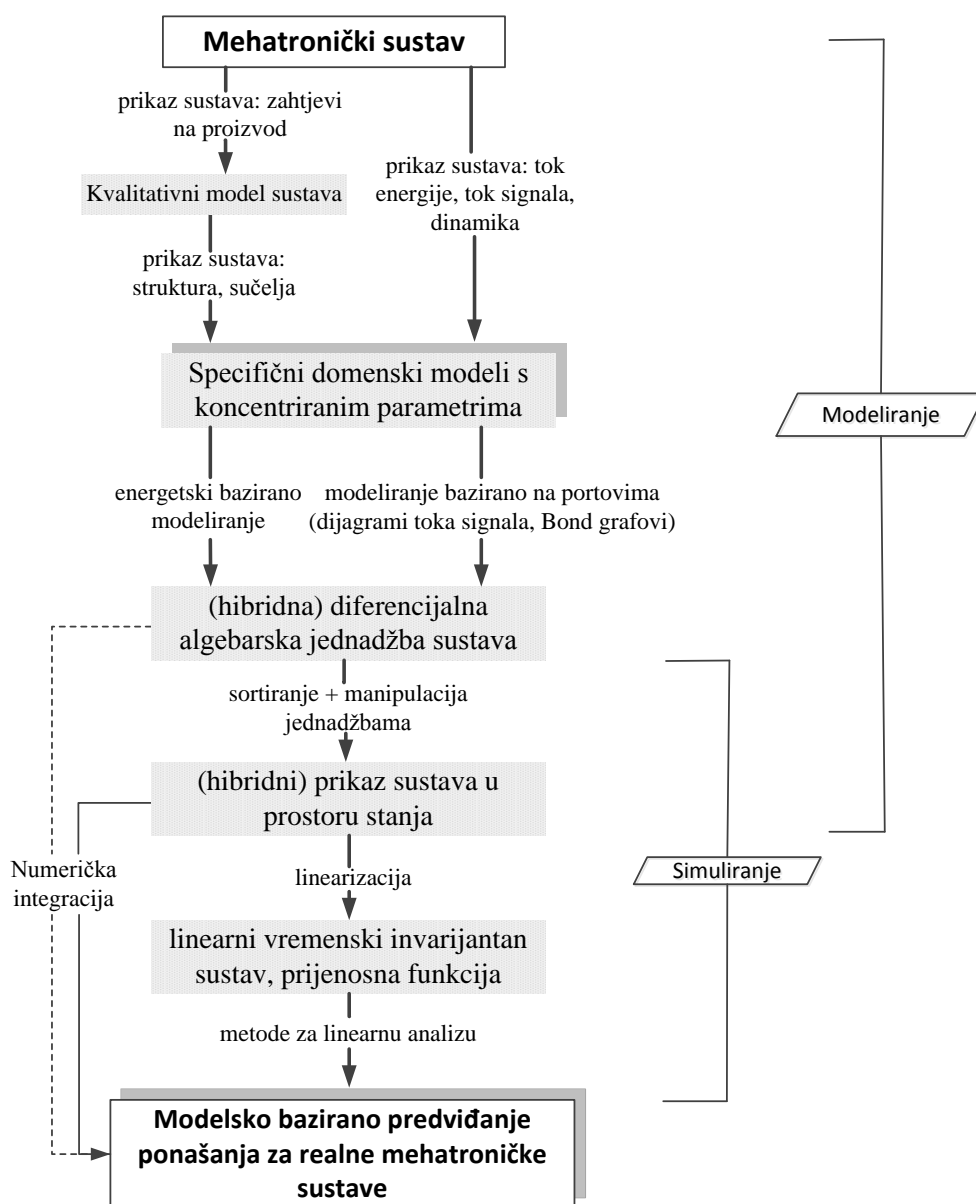
U mehatroničkom sustavu, pod važnim aspektima sustava uključuje se definiranje ponašanja sustava s obzirom na okolinu (odnosno korisnika) i pridjeljivanje pojedinih zadataka proizvoda pojedinoj funkciji (u smislu ostvarivog zadatka). U isto vrijeme, definiraju se preliminarna funkcijska struktura sustava kao i važna funkcijska sučelja.

Kod kvantitativnog predviđanja ponašanja sustava [104], generiraju se prikladni matematički modeli. Da bi se to provelo, treba uzeti u obzir protok energije, mase i signala, te dinamike unutar i između funkcija sustava, određenih u kvalitativnom modelu.

Kod mehatroničkih sustava postoji veliki broj razmatranih različitih fizikalnih domena (električna, mehanička, hidraulička, toplinska itd.).

Stoga je ovdje potrebno znanje razumijevanja različitih tehničkih područja, koje će se koristiti kao osnova prilikom modeliranja sustava.

Kod kreiranja modela pozornost treba obratiti na činjenicu da interakcija kod pojedinih elemenata sustava iz različitih fizikalnih domena, uvijek ide putem protoka energije sa povratnim efektima. Kao rezultat trebao bi se dobiti cjelokupno heterogeno spregnuto ponašanje sustava prikazano preko domenski ovisnih modela.



Slika 3.4. Hijerarhija matematičkih modela u razvoju mehatroničkih sustava [104]

Kod modeliranja više fizikalnih domena, postoji samo nekoliko prikladnih metodologija modeliranja [104]. Kod razmatranja sustava s koncentriranim parametrima, prikladna su dva metodološka principa. Prvi pristup je modeliranje bazirano na energiji, tzv. energetska bazirano modeliranje, korištenjem Lagrange-ovog formalizma, što je primjenjivo za manje sustave sa nelinearnim jednadžbama.

Drugi pristup se bazira na tzv. “višeportovskom” modeliranju (engl. *Multi-port modelling*), koje je opet prikladno za velike sustave. Ova skupina u kombinaciji sa objektno orijentiranim metodama danas se rješava putem računalnih alata primjenjivih za višedomensko modeliranje i simuliranje.

Krajnji rezultat različitih metodologija modeliranja su tzv. diferencijalno – algebarske jednadžbe. To su općenito nelinearni sustavi diferencijalnih i algebarskih jednadžbi koje u sebi uključuju relevantne varijable sustava. Oni su konačni domensko neovisni matematički modeli u kojima su zastupljeni svi fizički fenomeni sustava. Treba pritom reći da se manji dio fizikalnih fenomena (kao što su npr. operacije isključivanja/ uključivanja, kontakti problemi u mehanici, statičko trenje – u smislu obrade informacija), prikazuju tzv. proširenim matematičkim modelom. Taj model u sebi uključuje i fenomene diskretnih događaja, a naziva se model hibridnog sustava.

3.5. Metoda modelskog prediktivnog upravljanja

Svim algoritmima modelskog prediktivnog upravljanja zajednički je osnovni koncept, koji se temelji na sljedećem [105]:

- koristi se matematički model u cilju predikcije izlazne veličine procesa tijekom određenog budućeg vremena (predikcijskog horizonta),
- proračunu upravljačke sekvence, koja se dobiva minimizacijom kriterijske funkcije,
- strategiji pomičnog horizonta koja podrazumijeva pomicanje predikcijskog horizonta u svakom vremenskom uzorku za jedan korak u budućnost, te ponavljanje proračuna upravljačkog signala.

Bitno je navesti prednosti koje nudi modelsko prediktivno upravljanje [105]:

- može se primijeniti na procese značajno različitih ponašanja: statičke, astatičke, minimalno i neminimalno fazne, s dobro ili loše prigušenim polovima ili za nestabilne procese, sa ili bez mrtvog vremena,

- jednostavno im je podešavati parametre, što ih čini prikladnim osobama koje nemaju veliko predznanje (radnog iskustva) iz teorije automatskog upravljanja,
- jednostavna im je primjena na procese s više ulaza i više izlaza, tzv. MIMO (engl. *Multiple Input – Multiple Output*) procese,
- jednostavna implementacija unaprijednog upravljanja unutar algoritma predikcijskog upravljanja radi kompenzacije mjerljive smetnje,
- moguće je poboljšanje ponašanja sustava kod kojih se unaprijed poznaje referentna trajektorija.

Uz sve to ova metoda, imaju i neke nedostatke (ovdje se navode samo oni najvažniji) ([105], [106]):

- složenost proračuna čini ih značajno kompliciranijim (od npr. PID regulatora), što umanjuje mogućnost njihove primjene, te postavlja dodatne zahtjeve u pogledu računalne snage opreme na kojoj se izvršava algoritam predikcijskog upravljanja,
- kako su zasnovani na matematičkom modelu, potrebno je taj matematički model odrediti teorijskom analizom ili identificirati, a što otežava rad s ovim regulatorima.

Princip metode modelskog prediktivnog upravljanja se prema ([105], [107]), odvija tako da on u svakom diskretnom vremenskom koraku izračunava predikciju izlaza procesa za definirani predikcijski horizont N_2 , a sve na osnovi: matematičkog modela procesa, vektora prošlih upravljačkih vrijednosti \mathbf{u} , vektora prošlih izlaza procesa \mathbf{y} i predikcijskog vektora upravljačke veličine $\hat{\mathbf{u}}$ kojeg tek treba odrediti.

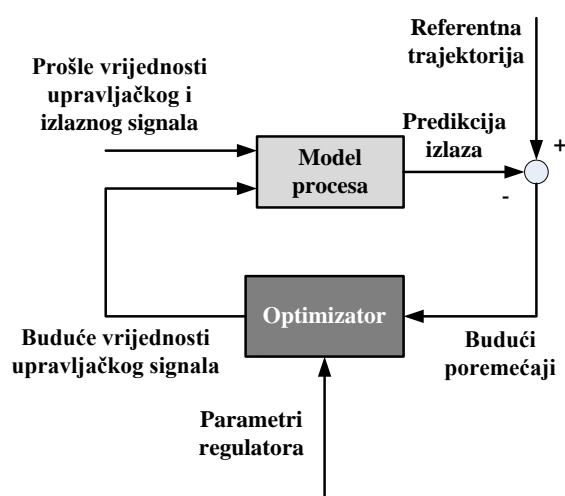
Predikcijski vektor upravljačke veličine proračunava se minimizacijom određene kriterijske funkcije koja ima za cilj dovesti buduće vrijednosti izlaza procesa \mathbf{y} , što je moguće bliže referentnoj trajektoriji \mathbf{w} . Zbog samog pojednostavljenja proračuna uvodi se upravljački horizont N_U , koji definira koliko će vremenskih uzoraka biti aktivan upravljački signal, a zatim će poprimiti konstantnu vrijednost.

Nakon što se izračuna predikcijski vektor upravljačke veličine, njegov prvi element $u(k)$ šalje se na izlaz regulatora, dok se svi ostali elementi zanemaruju i odbacuju. Postupak proračuna se ponavlja i u slijedećem vremenskom koraku, što čini princip tzv. *pomičnog horizonta* (engl. *Receding Horizon*).

Na slici 3.5. prikazana je struktura poopćenog modelskog prediktivnog regulatora [97]. Kao što se vidi sa slike, model procesa, pomoću prošlih vrijednosti upravljačkog i izlaznog signala, te budućih vrijednosti upravljačkog signala proračunava buduće vrijednosti izlazne veličine procesa.

Optimizator, korištenjem parametara regulatora, izračunava optimalni prediktor upravljačke veličine koji minimizira razliku između željene referentne trajektorije i prediktora izlazne veličine u nekom zadanom budućem vremenu.

Matematički model procesa se može odrediti teorijskom analizom (ili kažemo modeliranjem procesa), ali se češće određuje eksperimentalnom analizom (postupcima).



Slika 3.5. Struktura poopćenog modelskog predikcijskog regulatora [105]

Općenito algoritmi predikcijskih regulatora, često se razlikuju samo po tome koji matematički model koriste. Kod njih je uobičajeno koristiti model impulsnog odziva, prijelazne funkcije, prijenosne funkcije ili modela u prostoru stanja.

Optimizator predstavlja središnji dio regulatora. On uz zadane parametre regulatora, izračunava optimalni predikcijski upravljački vektor, takav da on unaprijed minimizira definiranu kriterijsku funkciju. U općem slučaju ona se sastoji od dva dijela: prvi dio funkcije predstavlja mjeru odstupanja prediktora izlaza procesa od referentne trajektorije, a drugi definira aktivnost upravljačkog signala.

Parametre sustava postavlja projektant sustava upravljanja. Oni omogućavaju udešavanje ponašanja tog sustava, a sve sa ciljem postizanja željene kakvoće upravljanja. Pri tom kriterije kakvoće upravljanja definiramo u vremenskoj domeni, a parametre predikcijskih regulatora uzimamo isključivo kao parametre kriterijske funkcije.

Veza između parametara regulatora i pokazatelja kvalitete upravljanja je izrazito nelinearna, no za razliku od drugih regulatora, ona je veoma intuitivna, te se jednostavnim podešavanjem parametara regulatora vrlo brzo može postići željena rezultati dobiveni simulacijom ponašanja sustava.

3.6. Metode određivanja stabilnosti dinamičkih sustava po Ljapunovu

Metoda stabilnosti po Ljapunovu ([72], [76], [80]), razmatra stabilnost sustava u okolini ravnotežnog stanja. Kako se nepobuđeni sustav, nalazi u ravnotežnom stanju, stanje sustava ostat će nepromijenjeno, tj. sustav će trajno zadržati ravnotežno, odnosno početno stanje. Kada bismo željeli provesti njegovu analizu stabilnosti, morali bismo pretpostaviti da sustav kreće iz početnog stanja, koje se nalazi negdje u okolini ravnotežnog stanja.

Sustav mora biti podvrgnut pobudama (kao što su šumovi mjerenja, poremećaji itd.), koje će ga pomaknuti iz ravnotežnog stanja. *A.M. Ljapunov*, dokazao je u svojoj doktorskoj disertaciji, 1892. godine, [79], teoreme, prema kojima su definirani različiti koncepti stabilnosti.

Prva metoda teorije stabilnosti po Ljapunovu ([72], [76], [80]), razmatra ponašanje rješenja izravne diferencijalne jednadžbe, kada početno stanje nije ravnotežno stanje. Pritom možemo razmatrati stabilnost stanja u malom, odnosno *lokalnu stabilnost*. Postoji slučaj koji je moguće razmatrati, kada je početno stanje po volji daleko od ravnotežnog stanja, tada se razmatra stabilnost ravnotežnog stanja u velikom, odnosno tzv. *globalna stabilnost*. U ovoj metodi razlikujemo tri slučaja stabilnosti: *asimptotsku*, *uniformu* i *eksponencijalnu stabilnost*, te *slučaj nestabilnosti*.

Druga metoda za analizu stabilnosti, koja će biti primijenjena i u doktorskom radu je tzv. *izravna metoda ili druga metoda Ljapunova* ([72], [76], [80]). S vremenom se pokazalo da je ova metoda puno prikladnija za određivanje stabilnosti. Ljapunov je u biti poopćio istraživanje *Lagrangea* iz 18. stoljeća, na način da je promatrao funkciju koja ima određena svojstva, kao i funkcija energije stabilnog ravnotežnog stanja (nazvana funkcija Ljapunova). Ovisno o prirodi Ljapunovljeve funkcije može se zaključiti o stabilnosti ravnotežnog stanja. Prema toj metodi postoji dva slučaja stabilnosti: *stabilno stanje* i *asimptotska stabilnost*, te *nestabilno stanje*.

3.7. Sustavi odlučivanja bazirani na neizrazitoj logici

Koncept *Neizrazite logike* (engl. *Fuzzy Logic*), uveden je u sklopu *Teorije neizrazitih skupova* (engl. *Fuzzy Sets*) autora *Zadeha* (prema [108], [109]), kojeg još nazivaju i ocem neizrazite logike. U prvo vrijeme razvoj područja neizrazite logike, vezao se uz društvene znanosti, no ipak je kasnije punu afirmaciju dostigao u tehnici, gdje se i dan danas koristi u širokom rasponu industrijskih i znanstvenih primjena [110].

Općenito, *neizrazitim sustavom* (engl. *Fuzzy system*), možemo nazvati bilo koji statički ili dinamički sustav koji koristi principe neizrazite logike te matematičke teorije, kao što su teorija neizrazitih skupova, neizrazita pravila i neizrazito zaključivanje [111]. Pod ovom definicijom u literaturi nalazimo mnoge neizrazite sustave kao što su: *neizraziti model* (engl. *Fuzzy model*), *neizraziti ekspertni sustav* (engl. *Fuzzy expert system*) te *sustav s neizrazitim pravilima* (engl. *Fuzzy rule based system*) ([112], [113]).

Prema slici 3.6. možemo vidjeti da svi sustavi odlučivanja pomoću pravila koja se baziraju na neizrazitoj logici (engl. *Fuzzy rule based system*, *Fuzzy Inference Systems (FIS)*), sadrže neke iste osnovne dijelove [114]:

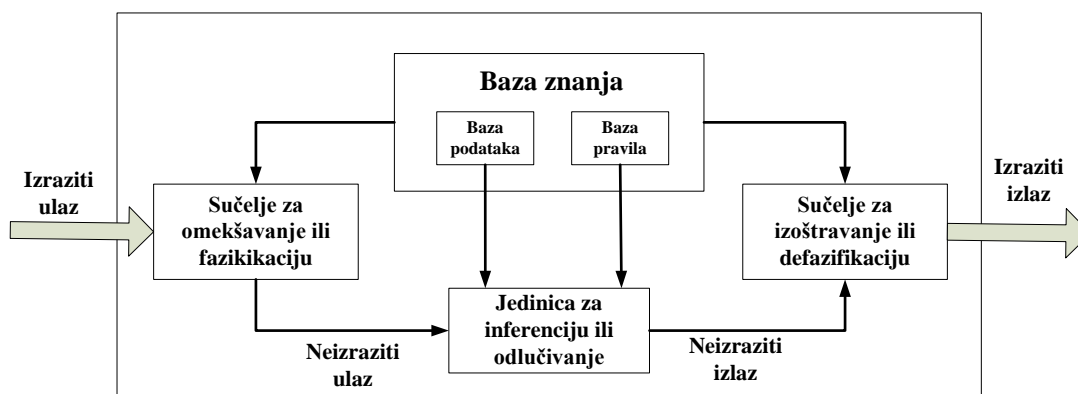
- a) *Sučelja za omekšavanje ili fazifikaciju* (engl. *Fuzzification*) – blok digitalno neizrazite pretvorbe, izraziti ulazni podaci mogu se promatrati i kao poseban oblik neizrazitog skupa, tzv. *singleton*. Omekšavanje je proces transformiranja ulaznih izrazitih vrijednosti u stupnjeve pripadnosti ulaznih neizrazitih skupova [115].
- b) *Sučelja za izoštravanje ili defazifikaciju* (engl. *Defuzzification*) – izlazni blok neizrazito–digitalne pretvorbe, izlaz također može biti i izrazita veličina. Izoštravanje je proces transformiranja neizrazitih izlaznih skupova u izrazite izlazne vrijednosti [115].
- c) *Baze znanja* (engl. *Knowledge database*) – koja u sebi sadrži bazu podataka s funkcijama pripadnosti (engl. *Membership functions*), te bazu neizrazitih pravila tipa „*if-then*“ (engl. *Fuzzy „if – then“ rules*),
- d) *Jedinice za inferenciju ili odlučivanje (zaključivanje)* (engl. *Decision making unit*). Inferencija je proces transformiranja ulaznih neizrazitih skupova u neizrazite izlazne skupove [115].

Dijelovi a), b) i d) zajedno čine cjelinu koja se naziva *neizraziti mehanizam odlučivanja (zaključivanja)* (engl. *Fuzzy reasoning mechanism*). Mehanizmi inferencije ili odlučivanja (zaključivanja) mogu se načelno podijeliti u dvije osnovne skupine [109]: oni koji se baziraju na globalnom, te oni koji se baziraju na lokalnom odlučivanju (zaključivanju).

Kod globalnog odlučivanja (zaključivanja) koristi se neizrazita relacija koja obuhvaća čitavu bazu pravila, a točnost relacije, izravno ovisi o gustoći diskretizacije domena ulaznih i izlaznih varijabli.

Kod lokalnog odlučivanja (zaključivanja) izračunavaju se samo ona pravila koja su u promatranom trenutku relevantna s obzirom na vrijednost ulaznih varijabli. Najznačajniji modeli lokalnog odlučivanja su: *Mamdani* [117] i *Takagi-Sugeno model* [118].

Mamdani tip sustava odlučivanja baziranog na neizrazitoj logici (engl. *Mamdani Fuzzy Inference System*), bazira se na principu primjene neizrazite logike u kvantificiranju jezičnih pravila. Neizrazita pravila ponašanja kreiraju se na osnovu ulaznih i izlaznih varijabli (može biti više ulaznih i više izlaznih varijabli) ([116], [117]).



Slika 3.6. Osnovna arhitektura sustava odlučivanja pomoću pravila bazirana na neizrazitoj logici [114]

3.8. Implikacije na rad

Poglavljem su obrađene teoretske osnove istraživanja, gdje su ukratko opisane i prikazane metode, metodologije i modeli bitne za dalje definiranje i objašnjenje pristupa u razvoju arhitektura složenih tehničkih sustava. Spomenuto je pristup inženjerstva sustava na kojem se temelji i doprinos prikazan u doktorskom radu. Uz to naglasak je stavljen na metodologiju konstruiranja mehatroničkih proizvoda (prema VDI 2206), koja prikazuje sistematični pristup razvoju i validaciji mehatroničkih sustava.

Uz to prikazuje i hijerarhiju modela tehničkih sustava, dobivenih u fazi modeliranja. Drugi naglasak je stavljen na teoriji područja, koja opisuje sintezu tehničkih proizvoda (sustava) njegovim promatranjem sa tri gledišta (područje transformacije, područje organa i područje komponenti). Ta tri pogleda prema navedenoj teoriji područja obuhvaćaju strukturnu i ponašajnu definiciju tehničkoga proizvoda. Dan je i kratak opis pristupa i modela, koji se koriste u matematičkom modeliranju pojedinog procesa, odnosno sustava. U nastavku se ukratko opisuju metode modelskog prediktivnog upravljanja i metode određivanja stabilnosti sustava prema Ljapunovu, koje se koriste u definiranju pristupa u slijedećem poglavlju. Navedenim metodama će se simulirati i ispitivati ponašanje tehničkog sustava. Na kraju je dan kratki opis sustava za odlučivanje baziranog na neizrazitoj logici. Osim što će se pomoću njega kreirati i zapisati neizrazita pravila ponašanja, omogućuje i grafički prikaz provedenog odlučivanja na bazi kreiranih pravila.

PRIJEDLOG ALGORITMA RAZVOJA ARHITEKTURA SLOŽENIH TEHNIČKIH SUSTAVA

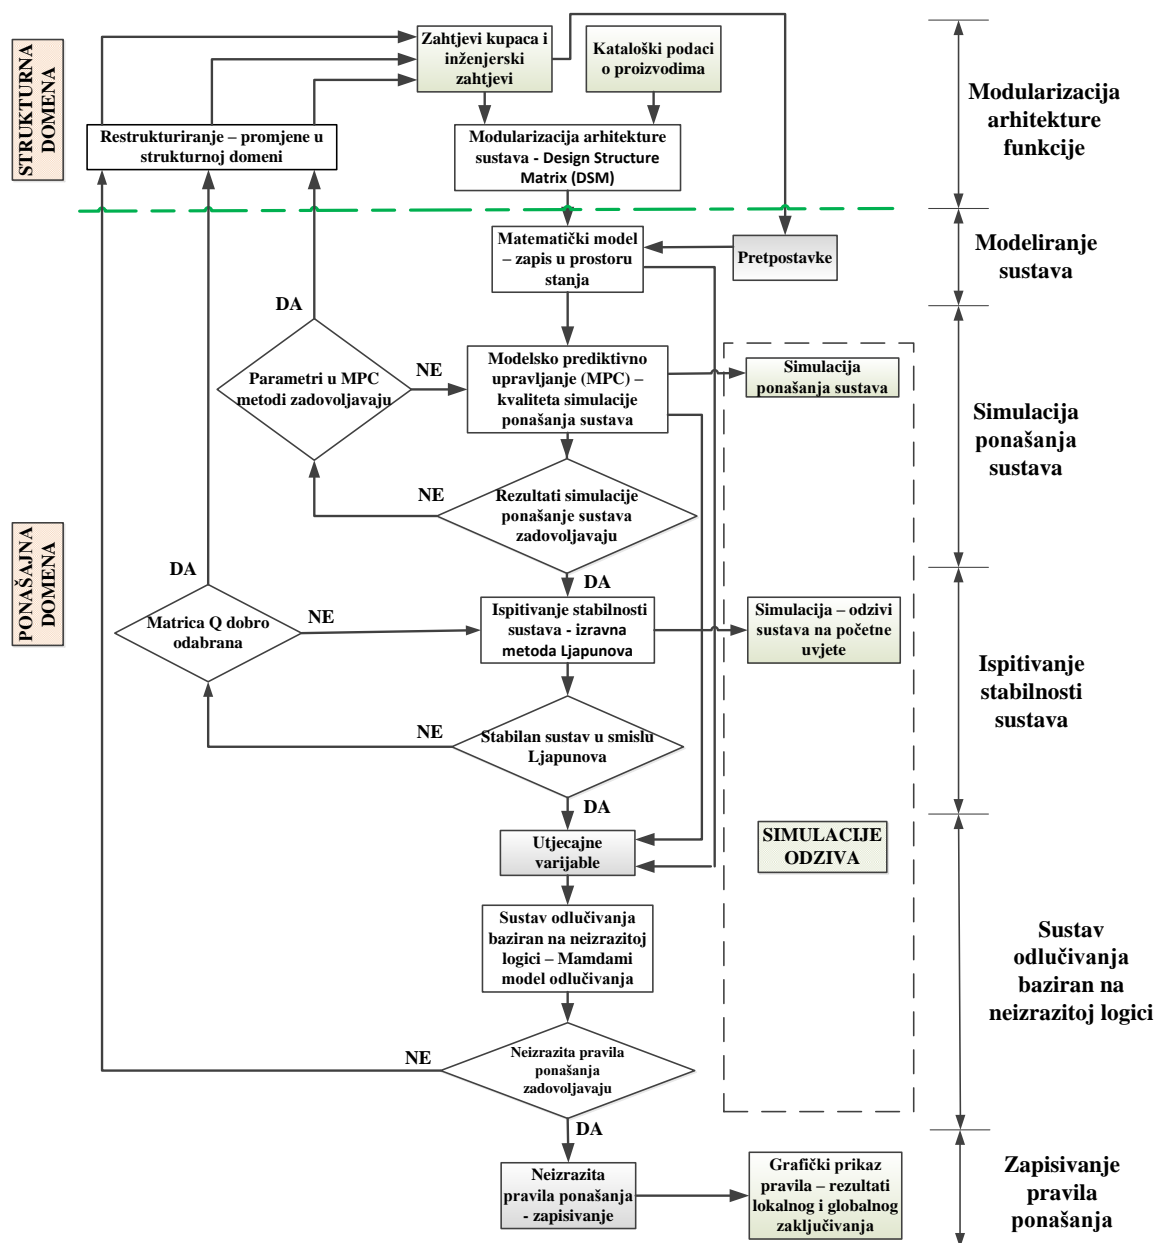
U ovom poglavlju objašnjen je prijedlog algoritma razvoja arhitektura složenih tehničkih sustava. Uz definiranje osnovnih operacija algoritma, u nastavku je svaka od njih pojedinačno detaljno opisana. Prvo je objašnjena modularizacija arhitekture sustava pomoću matrice komponenata (Design Structure Matrix - DSM) uz dani dijagramski prikaz. Nastavilo se s principom kreiranja matematičkog modela sustava (za kontinuiranu i diskretnu domenu), te njegovim zapisom u prostoru stanja. Slijedi opis kreiranja modela metode modelskog prediktivnog upravljanja (MPC), uz princip podešavanja parametara, te opisom dobivanja optimalnog izlaznog predikcijskog vektora. Dan je i dijagramski prikaz MPC metode sa pojedinim koracima. Slijedi opis ispitivanja stabilnosti sustava za kontinuiranu i diskretnu domenu izravnom metodom Ljapunova. Opis je potkrijepljen i dijagramskim prikazom. Nakon toga slijedi opis sustava za odlučivanje baziranog na neizrazitoj logici sa opisom pojedinih postupaka, kao i sam princip kreiranja neizrazitih pravila ponašanja. Prikazan je i shematski prikaz sustava za odlučivanje. Na kraju poglavlja dan je opis zapisa neizrazitih pravila ponašanja, te na koji način se izmjenjuju informacije između pojedinih operacija algoritma.

4.1. Prikaz algoritma

Algoritam razvoja arhitektura složenih tehničkih sustava, prikazan je dijagramom toka na slici 4.1. Dijagram prikazuje slijed operacija algoritma kroz strukturnu i ponašajnu domenu promatranog tehničkog sustava.

U nastavku je dan prikaz algoritma, uz kratke opise pojedinih operacija.

Kao što se može vidjeti sa prikazane slike, algoritam je iterativnog karaktera. To znači da je ponekad potrebno sprovesti više koraka kroz pojedine operacije putem povratnih petlji u strukturnoj i ponašajnoj domeni sustava. Time će se dobiti željena arhitektura složenog tehničkog sustava, koji bi uz definirane radne uvjete, mogao raditi i u neizvjesnim uvjetima okoline.



Napomena: opis prijenosa informacija između pojedinih operacija algoritma, dan je detaljnije pod točkom 4.8

Slika 4.1. Algoritam razvoja arhitektura složenih tehničkih sustava sa svojim pojedinim operacijama

Algoritam počinje operacijom u strukturnoj domeni, kojom se opisuje inicijalna (početna) arhitektura sustava. Opisuje se na temelju danih zahtjeva kupaca i iz njih kreiranih inženjerskih zahtjeva, te kataloških podataka o sličnim proizvodima. Za modularizaciju arhitekture sustava koristi se matrica komponenata DSM (engl. *Design Structure Matrix*). Gomilanjem elemenata DSM-a, kreiraju se mogući podsustavi (moduli) sustava.

Na osnovu dobivenih mogućih podsustava (modula), te definiranih početnih pretpostavki za matematički model (na temelju inženjerskih zahtjeva i iskustvu konstruktora), kreira se *matematički model ponašanja sustava*. Na osnovu pretpostavki uvode se moguća pojednostavljenja, nakon čega se kreiraju matematički modeli ponašanja za obje ponašajne domene (kontinuiranu i diskretnu). Dobiveni matematički modeli prikazuju se u prostoru stanja.

Pomoću kreiranih matematičkih modela ponašanja iz prethodne operacije, moguće je pristupiti simulaciji ponašanja sustava. U tu svrhu koristi se *metoda modelskog prediktivnog upravljanja* (engl. *Model Predictive Control - MPC*). Podešavanjem parametara, metoda računa optimalni predikcijski vektor izlaza, čiji se odziv(i) grafički prikazuju. Pritom se ocjenjuju rezultati odziva dobivenih MPC metodom. U slučaju kvalitetne simulacije ponašanja, kreće se u slijedeću operaciju. U suprotnom slučaju, vrše se promjene u prethodnim operacijama algoritma putem povratnih vezi. Prvo se promatra, da li je moguće promjenom pretpostavki kod kreiranja matematičkog modela, te promjenama parametara u MPC metodi utjecati na kvalitetu simulacije ponašanja sustava. Ako to nije moguće, vrše se promjene u strukturnoj domeni (operacija restrukturiranja). Pritom se uklanjaju postojeći ili uključuju novi elementi sustava (moduli ili podsustavi) u arhitekturu sustava. Restrukturiranje se bazira na iskustvu konstruktora.

Nakon toga sve operacije koje nakon toga slijede se ponavljaju, te se ponovo ispituje rezultati simulacije ponašanja sustava. Prikaz odziva dobivenih simulacijom, moguće je grafički prikazati (dijagramima) za oba slučaja, tj. neovisno o kvaliteti simulacije ponašanja sustava. Slijedi operacija *ispitivanja stabilnosti sustava*, gdje se promatrani sustav, tj. njegove ponašajne domene (kontinuirana i diskretna), ispituju korištenjem *izravne metode Ljapunova* (engl. *Ljapunov direct method*). Pritom valja istaknuti dva moguća slučaja.

Za izrazito linearne sustave i za nelinearne sustave, koji se daju prikazati u linearnom obliku, ispitivanje stabilnosti sustava provodi se kao da je promatrani sustav autonoman.

U slučaju neizrazito nelinearnih sustava (koji bi prikazom u linearnom obliku izgubili na svojstvima svog dinamičkog ponašanja), kod ispitivanja stabilnosti sustava, mora se uzeti u obzir sustav (zajedno sa MPC metodom). Kažemo da ga treba promatrati kao upravljani sustav.

U slučaju dobivanja nestabilnog sustava u smislu Ljapunova, vrše se promjene u prethodnim operacijama algoritma. Prvo se promatra (ovisno o maloprije opisanom tipu sustava), da li je moguće promjenom matrice Q utjecati na stabilnost sustava. Ako to nije moguće, vrše se promjene u strukturnoj domeni (operacija restrukturiranja). Tada se uklanjaju postojeći ili uključuju novi elementi sustava (moduli ili podsustavi) u arhitekturu sustava. Restrukturiranje se bazira na iskustvu konstruktora. Operacije algoritma koje nakon toga slijede se ponavljaju, te se ponovo ispituje stabilnost sustava u smislu Ljapunova. Kao i kod prethodne operacije i ovdje je moguće je grafički prikazati (dijagramima), odzive sustava na početne uvjete, neovisno o dobivenoj stabilnosti sustava.

Na osnovu dobivenih utjecajnih varijabli iz matematičkog modela (odabiru se na temelju iskustva konstruktora), te dobivenog znanja o ponašanju sustava (kroz operacije MPC metode i ispitivanja stabilnosti sustava), kreiraju se neizrazita pravila ponašanja sustava. Za tu svrhu koristi se *sustav odlučivanja baziran na neizrazitoj logici* (engl. *Fuzzy Rule Based System*). U slučaju zadovoljavajućih pravila ponašanja sustava, vrši se njihovo zapisivanje. U tom slučaju izlazni rezultat iz sustava odlučivanja može se promatrati grafički, na lokalnoj ili globalnoj razini odlučivanja (zaključivanja). U suprotnom slučaju (nezadovoljavajućih pravila ponašanja), provodi se putem povratne veze operacija restrukturiranja.

Cijeli maloprije opisani algoritam razvoja, primjenjiv je za slučajeve stvaranja potpuno novih arhitektura složenih tehničkih sustava. No može se provoditi i u slučaju mijenjanja arhitekture sustava sa svrhom poboljšanja njegovih performansi. Tada kažemo da mijenjamo pravila ponašanja, već nekom postojećem složenom tehničkom sustavu.

U nastavku se detaljnije opisuju pojedine operacije algoritma razvoja arhitektura složenih tehničkih sustava.

4.2. Modularizacija arhitekture sustava

Shema operacije modularizacije arhitekture sustava korištenjem matrice komponenata DSM-a, dana je na slici 4.2.

Koraci operacije su pobrojani i ukratko opisani u nastavku teksta, kako slijedi:


1. Kreiranje matrice komponenata – prema definiranim zahtjevima kupaca i iz njih kreiranih inženjerskih zahtjeva, te na bazi kataloških podataka o sličnim proizvodima.

U matricu se upisuju inicijalne komponente sustava, te eventualno uključuju nove ili uklanjaju postojeće tokom koraka iteracije u algoritmu ([26], [27], [119]).

2. Određuje se interakcija između komponenata sustava (sukladno [119]). Interakcije mogu biti podaci o: materijal – M, energija – E ili informacija – I.

3. Označavaju se interakcije među komponentama sustava u matrici.

4. Provodi se triangularizacija matrice, gdje se ona preslaguje s ciljem minimiziranja povratnih petlji u matrici ([23], [24]). Tim postupkom ih pomičemo što je moguće više bliže dijagonali matrice. Po završetku počinje se nazirati transparentna donje trokutasta struktura. To znači da je što manje komponenata sustava uključeno u procese ponavljanja, tj. povratne petlje u matrici.



Slika 4.2. Modularizacija arhitekture sustava

Preslagivanjem (gomilanjem) matrice se identificiraju se nakupine (klasteri, gomile) minimalno isključivih komponenata ([23], [24]).

Tako se formiraju podsustavi (module), tj. neovisne skupine elemenata unutar sustava.

Cilj postupka je kreirati module koji u sebi sadrže većinu ili čak sve interakcije, dok su interakcije između različitih nakupina minimizirane ili eliminirane. Tako koncipirani moduli predstavljaju grupu funkcionalno ili strukturalno neovisnih komponenata, čije međudjelovanje je uglavnom usmjereno unutar svakog modula.

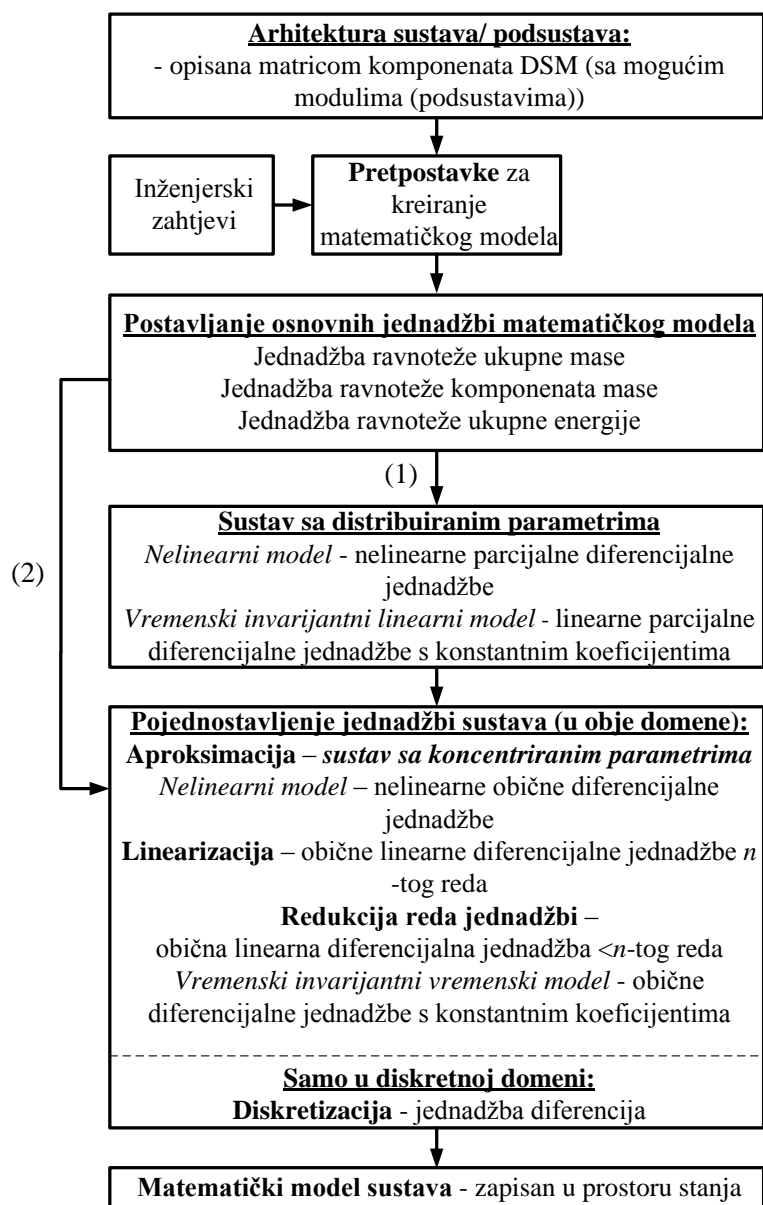
Kao rezultat modularizacije arhitekture sustava dobiva se prikaz složenog tehničkog sustava, zapisan u matričnom obliku. U matrici komponenata označavaju se dobiveni mogući podsustavi (tj. moduli).

4.3. Modeliranje sustava

Ukratko će po koracima biti opisana operacija kreiranja matematičkog modela sustava i to teoretskom analizom za obje ponašajne domene (kontinuiranu i diskretnu), te zapis tog modela u prostoru stanja (prikazano na slici 4.3.).

Kreiranje matematičkog modela ponašanja sustava možemo opisati sljedećim koracima ([33], [34], [101]):

1. Uvode se pretpostavke za kreiranje matematičkog modela. Pritom se koristi trenutno kreirana arhitektura podsustava/ ili sustava kojeg razmatramo (opisano u točki 4.2.), uz već prethodno definirane inženjerske zahtjeve koji se postavljaju na podsustav (i/ ili sustav). Arhitektura sustava već opisuje moguće podsustave (module).
2. Ovisno o tipu procesa u promatranom podsustavu ili sustavu kojeg modeliramo postavljaju se osnovne jednačbe matematičkog modela (jednačbe ravnoteže ukupne mase, jednačbe ravnoteže komponenata mase i jednačbe ravnoteže ukupne energije). Osnovne jednačbe određuju i karakter promatranog procesa u podsustavu, odnosno sustavu. Kaže se da se pri modeliranju matematički formuliraju interakcije između promatranih podsustava [73]. Na osnovu uvedenih pretpostavki iz prethodnog koraka operacije provode se moguća pojednostavljenja matematičkog modela, time što se mijenjaju prethodno postavljene osnovne jednačbe, zanemarivanjem nekih od članova dotičnih jednačbi. Bitno je napomenuti da ovisno o tipu osnovnih jednačbi matematičkog modela ponašanja razlikujemo i tri osnovna tipa pohranjivane veličine [33]. One mogu biti: masa i/ili energija i/ili impuls (promatramo procese (podsustave i/ ili sustave) s inercijskim svojstvima, govorimo o količini gibanja) ([33], [101]).



Slika 4.3. Algoritam kreiranja matematičkog modela teoretskom analizom za obje ponašajne domene (kontinuiranu i diskretnu)

Vremenske promjene tih pohranjivanih veličina (prema [33]) su posljedice neuravnoteženosti tokova masa i/ili energije i/ili impulsa u promatranim procesima (podsustavima i/ ili sustavima). Ovdje se postavlja pitanje koji tip sustava razmatrati, da li s distribuiranim (raspodijeljenim) parametrima ili s koncentriranim parametrima.

Gledajući generalno, svi procesi u tehničkim sustavima ima svojstvo *sustava s distribuiranim (raspodijeljenim) parametrima*, zbog konačnosti brzine kojom se šire poremećaji, kao i brzine promjene varijabli sustava.

Kažemo da takvi sustavi imaju svojstvo prostorne (volumne) raspodijeljenosti [33]. Stoga se kod postavljanja matematičkog modela sustava uvijek uzima u obzir pitanje ispravnosti zanemarivanja te ovisnosti. Sagledavajući s činjenice da tako dobiveni matematički modeli imaju oblik nelinearnih parcijalnih diferencijalnih jednačbi, to u mnogome otežava njihovu primjenu u analizi ponašanja sustava ([33], [73]).

Također ne postoje jedinstveni stavovi u literaturi kada se neki sustav treba promatrati kao sustav s raspodijeljenim parametrima. No ovdje se navodi jedno objašnjenje kada sustav treba modelirati sa distribuiranim (raspodijeljenim) parametrima. To se prema [73] „radi samo onda kada je to u konkretnom slučaju nužno s obzirom na potrebnu točnost modela, odnosno kada na dinamička svojstva cijelog regulacijskog sustava utječu upravo ona dinamička svojstva komponente koja su uvjetovana raspodijeljenošću proces akumulacije i transporta fizikalnih veličina po volumenu njena prostora“. Primjeri takvih sustava su prema [33] npr. procesi prijenosa mase i energije (npr. transport rasutog materijala, konvektivni prijenos topline u toplinski neizoliranoj cijevi strujanjem tekućine itd.), procesi izjednačavanja (provođenje topline kroz homogeno izolirano tijelo, debelostijeni direktni izmjenjivač topline itd.), te procesi periodičnih promjena stanja (aksijalne vibracije konzole, procesi u cjevovodima za transport fluida itd.). Nelinearni model sustava s distribuiranim (raspodijeljenim) parametrima prikazuje se nelinearnom parcijalnom diferencijalnom jednačbom (prikazano na slici 4.3.) [73]. Nelinearni model moguće je procesom linearizacije prevesti u linearni oblik. Tako ih se procesom linearizacije može prevesti u oblik linearnih parcijalnih diferencijalnih jednačbi. Proces linearizacije predstavlja zamjenu nelinearnih matematičkih izraza kojima su povezane varijable stanja s linearnim izrazima. Linearizacija se može opravdati, a za to postoje i neki razlozi, kao ([33], [73]):

- kod malih odstupanja od uobičajenih radnih režima, linearni model se ponaša kao i izvorni nelinearni proces,
- dobiva se mogućnost generalizacije (jedinstvenog pristupa) kod modeliranja dinamičkog ponašanja pojedinog procesa. Koristi se tzv. princip superpozicije, što vodi k poopćavanju i jedinstvenom promatranju dinamike pojedinog procesa.

Postoji više vrsta linearizacije, no u ovom radu je primijenjena metoda tangentne aproksimacije ili linearizacija u blizini radnog (uglavnom stacionarnog) stanja.

Navedenom metodom se nelinearna karakteristika zamjenjuje linearnom (što u dvodimenzionalnom slučaju predstavlja zamjenu krivulje tangentom u radnoj točki). Gledajući s matematičkog stajališta to predstavlja razvoj funkcije u Taylorov red u kojem se odbacuju (zanemaruju) svi viši (nelinearni) članovi razvoja. Postupak linearizacije je uspješniji time što je odstupanje od radnog stanja manje [33].

Ako bi se sustav s distribuiranim parametrima promatrao kao linearni i to vremenski invarijantni, tada ga prikazujemo linearnom parcijalnom diferencijalnom jednačbom s konstantnim koeficijentima. Ako će se pri izradi matematičkog modela sustav promatrati kao sustav sa raspodijeljenim parametrima, tada treba prema dijagramu toka prikazanom na slici 4.3. krenuti opcijom (1).

No u većini slučajeva pri izradi matematičkog modela ponašanja sustava često nije nužno da model procesa u promatranom podsustavu ili sustavu odražava dinamička svojstva koja su uvjetovana poljima varijabli unutar cjelokupnog volumena sustava. Pritom je sasvim dovoljno da se stanje procesa akumulacije u podsustavu ili sustavu u svakom trenutku vremena definira njihovom srednjom vrijednosti [73]. U takvom slučaju sustav promatramo kao *sustav s koncentriranim parametrima*. Kod matematičkog modeliranja takvih sustava pretpostavlja se da je kod svih njih zanemarena prostorna ovisnost promatranih varijabli, odnosno promjena tih veličina smatra se jednakom i istovremenom po cijelom volumenu za koji su postavljene jednačbe održanja [33]. Također može se reći i da je kod navedenih sustava promjena promatrane veličine stanja na red veličine, traje duže od vremena koje je potrebno da se poremećaj te veličine stanja proširi po cijelom prostoru u kojem se taj proces odvija. Matematički gledano može se reći da se dobiva model sustava sa zadovoljavajućom točnošću. Prema [33] procese u sustavima s koncentriranim parametrima možemo promatrati kao osnovne i složene. Osnovni procesi pritom mogu biti npr.: pohranjivanje mase (npr. spremnici tekućina i spremnici plinova i para), procesi strujanja fluida (npr. strujanje tekućine, strujanje plinova i para), toplinski procesi i mehanički procesi. Složeni procesi u sustavima s koncentriranim parametrima nastaju kombiniranjem nekih od navedenih osnovnih procesa, kao npr. serijski spojena dva spremnika tekućina, serijski spojeni izmjenjivači topline, spremnik dvofaznog fluida, mehanički servo sustav itd. Nelinearni model sustava s koncentriranim parametrima općenito se prikazuje nelinearnim običnim diferencijalnim jednačbama (prikazano na slici 4.3.).

Kao i kod sustava s distribuiranim (raspodijeljenim) parametrima) nelinearni matematički model ponašanja sustava moguće je procesom linearizacije prevesti u linearni oblik. Tada se dobiva oblik običnih linearnih diferencijalnih jednačbi n -tog reda. U slučaju linearnih vremenski invarijantnih sustava, njihov matematički oblik se prikazuje običnim linearnim diferencijalnim jednačbama s konstantnim koeficijentima. Taj oblik dobiva se redukcijom reda običnih linearnih diferencijalnih jednačbi n -tog reda. Ako će se pri izradi matematičkog modela sustav promatrati kao sustav sa raspodijeljenim parametrima, tada treba prema dijagramu toka prikazanom na slici 4.3. krenuti opcijom (2).

Kod diskretne domene se nekim od postupaka diskretizacije prevodi linearni model vremenski invarijantnog sustava u diskretni oblik. Tada se dobiju jednačbe diferencije. Također oblik sustava s distribuiranim parametrima, može se postupkom aproksimacije prevesti u oblik sustava s koncentriranim parametrima.

3. Dobivenim matematičkim modelom sustava opisuje se njegovo ponašanje u obje ponašajne domene (kontinuiranoj i diskretnoj). Sustav u kontinuiranoj domeni može se matematički prikazati [34] sa diferencijalnim jednačbama, prijenosnim funkcijama i frekvencijskim metodama. Ovisno o načinu matematičkog prikaza analiza ponašanja sustava može se provoditi u više područja (vremenskom, Laplaceovom i frekvencijskom). Također ponašanje sustava u diskretnoj domeni može se matematički prikazati [34] sa jednačbama diferencija, prijenosnim funkcijama i rekurzivnim jednačbama. Kao i kod kontinuirane domene i ovdje se analiza ponašanja sustava može provoditi u više područja (vremenskom, diskretnom i z području). U ovom radu koristit ćemo se matričnim prikazom matematičkog modela ponašanja sustava u kontinuiranoj i diskretnoj domeni u prostoru stanja. Takav prikaz daje nam jednostavan i pregledan matematički model sustava. On je naročito pogodan i uobičajen za opis matematičkih modela složenih sustava, tj. sustava sa više ulaza i izlaza, tzv. multivarijabilnih (MIMO) sustava [101]. Dobivene linearne diferencijalne jednačbe postupkom matematičkog modeliranja, mogu se za promatrane varijable stanja (ulazne i izlazne) smatrati i jednačbama odstupanja tih varijabli od nekog početnog stacionarnog stanja. Tada se za početne uvjete uzima da su jednaki nuli [33]. Tako dobivene jednačbe u matričnom obliku prostora stanja vrijede za promjenu apsolutnih vrijednosti varijabli od početnog stanja jednakog nuli. Također vrijede i za promjene odstupanja varijabli od početnog stacionarnog stanja.

Matematički modeli po varijablama stanja, osnivaju se na matematičkom modelu, tj. diferencijalnoj jednadžbi sustava, prikazanom u normalnom (Cauchy-evom) obliku [72]:

$$- \frac{dx_i(t)}{dt} = \sum_{j=1}^n a_{ij}(t) \cdot x_j(t) + \sum_{j=1}^p b_{ij}(t) \cdot u_j(t); i=1,2,\dots,n \quad (4.1.)$$

$$- y_l(t) = \sum_{j=1}^n c_{lj}(t) \cdot x_j(t) + \sum_{j=1}^p d_{lj}(t) \cdot u_j(t); l=1,2,\dots,q \quad (4.2.)$$

Jednadžbe (4.1.) i (4.2.) mogu se prikazati u matričnoj formi:

$$- \dot{x}(t) = \mathbf{A}(t)x(t) + \mathbf{B}(t)u(t) \quad (4.3.)$$

$$- y(t) = \mathbf{C}(t)x(t) + \mathbf{D}(t)u(t) \quad (4.4.)$$

Jednadžbu (4.3.) nazivamo *jednadžba stanja* ili *jednadžba dinamike stanja sustava*, a jednadžbu (4.4.), *jednadžba izlaza*, odnosno *algebarska jednadžbu izlaza*. Obje jednadžbe zajedno tvore *matematički model sustava u prostoru stanja (po varijablama stanja)*.

Varijable stanja su one veličine procesa kojih poznavanje u trenutku t_0 , a znajući zakone ponašanja ulaznih veličina u svakom trenutku $t > t_0$, u cijelosti omogućuje određivanje izlazne veličine za svaki $t > t_0$. Varijable stanja su vremenski promjenjive veličine (funkcije), a skup njihovih trenutnih vrijednosti daje stanje procesa, odnosno sustava.

Ukoliko je za opis nekog procesa neophodno poznavati n veličina stanja, onda se kaže da je proces (odnosno sustav) n -tog reda i njegov matematički opis moguće je dati sustavom od n diferencijalnih jednadžbi 1. reda.

Oznake u jednadžbama (4.3.) i (4.4.) su:

- t – vrijeme,
- $\dot{x} = \frac{dx}{dt}$ – vektor derivacija stanja,
- n – dimenzija stanja (broj varijabli stanja),
- x – vektor stanja,
- u – vektor pobude na sustav,
- p – dimenzija pobude (broj pobuda koje djeluju na sustav),
- y – vektor odziva sustava,
- q – dimenzija izlaza (broj izlaznih signala sustava),
- \mathbf{A} – matrica dinamike sustava,
- \mathbf{B} – matrica raspodjele upravljanja sustavom,

- \mathbf{C} – matrica mjerenja (senzora) sustava,
- \mathbf{D} – matrica izravnog prolaza pobude na izlaz sustava; kod realnih procesa jednaka je nul matrici.

Kako ovdje razmatramo linearne vremenski invarijantne sustave (engl. *LTI systems*), tada su matrice vremenski nepromjenjive, tj.

$$\mathbf{A}(t) = \mathbf{A}, \quad (4.5.)$$

$$\mathbf{B}(t) = \mathbf{B}, \quad (4.6.)$$

$$\mathbf{C}(t) = \mathbf{C}, \quad (4.7.)$$

$$\mathbf{D}(t) = \mathbf{D} \quad (4.8.)$$

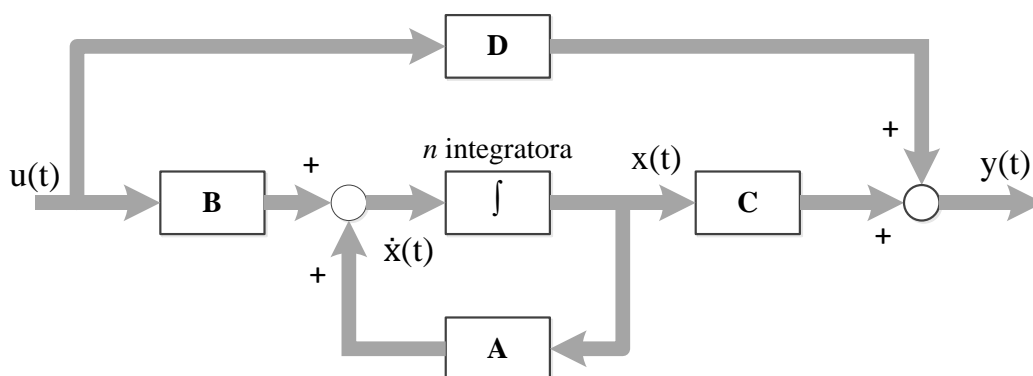
Tada se matematički model vremenski nepromjenjivog sustava u prostoru stanja može pisati:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) \quad (4.9.)$$

$$\mathbf{y}(t) = \mathbf{C}\mathbf{x}(t) + \mathbf{D}\mathbf{u}(t) \quad (4.10.)$$

Bitno je napomenuti da jednačbe ((4.9.) – (4.10.)) vrijede kako za SISO (engl. *Single Input – Single Output*) sustave, tako i za MIMO (engl. *Multiple Input – Multiple Output*) ili multivarijabilne sustave. Jedina razlika je u tome što skalarne veličine u i y postaju vektori koji sadrže sve ulaze i izlaze procesa. U ovom doktorskom radu bavimo se MIMO sustavima. Prema [72], *definicija prostora stanja* glasi: *Prostor stanja je n -dimenzionalni (Euklidski) prostor u kome su koordinate prostora komponente vektora stanja.*

Prema Kalmanu [120], *definicija stanja sustava* glasi: *Stanje sustava, matematička je struktura, koja sadrži skup od n -varijabli x_1, x_2, \dots, x_n , zvanih varijable stanja, koje omogućuju da ako se poznaju početne vrijednosti $x_i(t_0)$ toga skupa i signale pobude na sustav $u_j(t)$ za $t \geq t_0$, jednoznačno opiše odziv sustava za $t \geq t_0$.*



Slika 4.4. Blok shema (prikaz) MIMO sustava ([72], [121])

Na slici 4.4. prikazana je blok shema (prikaz) MIMO sustava u prostoru stanja ([72], [121]), prema jednadžbama (4.9.) i (4.10.).

4.4. Modelsko prediktivno upravljanje (MPC) metoda

Za provedbu simulacije ponašanja tehničkog sustava metodom modelskog prediktivnog upravljanja (MPC) potrebno je imati definiran matematički model sustava (procesa) kojeg promatramo (vidi točku 4.3. ovog poglavlja). Metoda će se provoditi sa linearnim, odnosno lineariziranim modelom sustava (procesa), zapisanim u prostoru stanja. MPC metoda može raditi i sa izrazito nelinearnim modelom, no u ovom radu to nije predmetom istraživanja.

Model sustava (procesa) služi za predviđanje (predikciju) budućih vrijednosti izlaza sustava (procesa) više koraka unaprijed.

Na temelju tih predviđenih vrijednosti i na temelju željenih vrijednosti koje definira referentni model izračunavaju se optimalne vrijednosti upravljačkog vektora, primjenom optimizacije neke kriterijske funkcije.

Uobičajeno je kod kontinuirane domene, prikaz modela prevesti u diskretni oblik (nekim od poznatih postupaka diskretizacije). To se radi iz razloga lakše obrade informacija, koje se i inače u računalu prikazuju u diskretnom zapisu.

4.4.1. Matematički modeli osnovnih vektora u MPC metodi

Na osnovu odabranih ulaznih i izlaznih varijabli u MPC metodi definiraju se njihovi matematički modeli. Matematički modeli tih vektora u metodi modelskog prediktivnog upravljanja (MPC) biti će objašnjeni na primjeru sustava s jednim ulazom i jednim izlazom (SISO sustava) (vidi sliku 4.5.) ([122]).

Na slici 4.5. dana je vremenska skala prikazana u koracima uzrokovanja, pri čemu koraku k odgovara trenutačno vrijeme. Definiramo slijedeće vektore prema ([105], [107], [122]):

$$\mathbf{u} = [u(k-1)u(k-2) \dots] \quad (4.11.)$$

$$\mathbf{y} = [y(k)y(k-1)y(k-2) \dots] \quad (4.12.)$$

$$\mathbf{w} = [w(k+1)w(k+2) \dots w(k+N_2)] \quad (4.13.)$$

$$\hat{\mathbf{u}} = [\hat{u}(k)\hat{u}(k+1) \dots \hat{u}(k+N_2-1)] \quad (4.14.)$$

$$\hat{\mathbf{y}} = [\hat{y}(k+1)\hat{y}(k+2) \dots \hat{y}(k+N_2)] \quad (4.15.)$$

gdje su:

\mathbf{u} – vektor prošlih izlaza regulatora,

\mathbf{y} – vektor mjerenih prošlih izlaza procesa (uključuje mjereni izlaz u trenutku $t=kT$),

\mathbf{w} – vektor referentne trajektorije (željeni izlaz procesa u budućnosti),

$\hat{\mathbf{u}}$ – predikcijski vektor izlaza regulatora (upravljačke veličine),

$\hat{\mathbf{y}}$ – predikcijski vektor izlaza procesa (proračunat na osnovu modela i vektora \mathbf{u} , \mathbf{y} i $\hat{\mathbf{u}}$),

N_1 – prvi predikcijski horizont,

N_2 – drugi predikcijski horizont,

N_U – upravljački horizont.

4.4.2. Podešavanje parametara u MPC metodi

Podešavanje parametara modelskog prediktivnog regulatora, prema [123], obuhvaća odabir vrijednosti za:

– predikcijske horizonte (N_1 i N_2); N_1 se odabire tako da približno odgovara mrtvom vremenu procesa u koracima uzorkovanja (ili vrijednosti 1, ako je mrtvo vrijeme zanemarivo).


– vrijeme uzorkovanja uzima se kao $1/20 - 1/15$ srednjeg vremena porasta zatvorenog regulacijskog kruga. Drugi predikcijski horizont obično se odabire tako da njime bude obuhvaćena cijela prijelazna pojava.

– uvođenjem upravljačkog horizonta N_U ograničavaju se nagle promjene upravljačkog signala čime se poboljšavaju rezultati simulacije ponašanja sustava, no istovremeno se smanjuje brzina odziva. Povećanjem N_U mogu se prigušiti i eventualne oscilacije u odzivu. Početno se odabire vrijednost $N_U = 1$, te se postupno povećava ako je to potrebno.

– koeficijente δ i λ ; za δ se obično uzima jedinični vektor, dok se za vektor λ odabiru vrijednosti reda veličine $10^{-3} - 10^{-2}$.

– vrijeme porasta referentne trajektorije ili vrijeme prvog maksimuma i prigušenje.

Nakon toga slijedi postavljanje mogućih ograničenja na upravljačke i izlazne varijable, uz podešavanje njihove težine na pojedinim varijablama. Podešavanje parametara završava sa postavljanjem parametara kod postavnih točaka i nemjerenih poremećaja.



Slika 4.5. Osnovni princip rada metode modelsko prediktivno upravljanje za SISO sustav [122]; a) prikaz stanja sustava upravljanja u trenutku $t = kT$, b) stanje sustava upravljanja u trenutku $t = (k+1)T$

4.4.3. Postupak računanja optimalnog predikcijskog vektora izlaza regulatora u MPC metodi

Postupak računanja optimalnog predikcijskog vektora izlaza regulatora prolazi kroz slijedeće korake ([105] - [107]):

a) formiranje referentne trajektorije

Referentna trajektorija predstavlja željeno ponašanje izlazne veličine procesa unutar predikcijskog horizonta N_2 . Na osnovu referentne vrijednosti w u trenutku $t = kT$ i izmjenjenog izlaza procesa $y(k)$ formira se vektor referentne trajektorije w koji opisuje željenu funkciju prijelaza izlaza procesa sa vrijednosti $y(k)$ na vrijednost w . Postoji više načina formiranja referentne trajektorije, a najčešća je prema filtru prvog reda kako bi oblikovala odziv sustava [122]:

$$w(k) = y(k), w(k+j) = \beta(k+j-1) + (1-\beta)r(k+j) \quad (4.16.)$$

gdje su:

β – težinski koeficijent referentne trajektorije; $0 \leq \beta \leq 1$,

w – trenutačna referentna vrijednost, odnosno referentna vrijednost u trenutku $t = (k+N_2)T$,

$r(k+j)$ – zadana referentna veličina sustava u trenutku $k+j$.

b) predikcija izlaza procesa

Predikcijski vektor izlaza procesa \hat{y} proračunava se na osnovu matematičkog modela procesa, te vektora u , y i \hat{u} . Postoje različiti modeli procesa, no svi moraju imati neka svojstva.

Potrebna svojstva koja mora imati neki način modeliranja da bi on bio prihvatljiv za primjenu metode modelskog prediktivnog upravljanja (MPC) [122]:

- mogućnost preciznog oponašanja dominantne dinamike procesa takvim modelom,
- mogućnost jednostavne i sustavne identifikacije procesa u tom obliku,
- postojanje aparata za rješavanje određenih klasa upravljačkih problema za takav model,
- mogućnost teoretske analize MPC-a s takvim modelom,
- intuitivnost rada s modelom.

Model procesa za MIMO sustav se u poopćenom modelskom prediktivnom regulatoru preračunava u diskretni oblik u prostoru stanja [107].

Takav model spada u grupu unutarnjih modela, jer oni osim ulazno/ izlaznih odnosa opisuju stanja varijabli procesa, a izraz koji se ovdje koristi je prema *Isermanu* [124]:

$$x(k+1) = \mathbf{A}x(k) + \mathbf{B}u(k) \quad (4.17.)$$

$$y(k) = \mathbf{C}x(k) + \mathbf{D}u(k) \quad (4.18.)$$

gdje su:

x – vektor varijabli stanja,

u – vektor ulaznih veličina,

y – vektor izlaznih veličina,

\mathbf{A} – matrica dinamike sustava,

\mathbf{B} – matrica raspodjele upravljanja sustavom,

\mathbf{C} – matrica mjerenja (senzora) sustava,

\mathbf{D} – matrica izravnog prolaza pobude na izlaz sustava; kod realnih procesa jednaka je nul matrici.

Predikcija izlaza računa se prema izrazu:

$$y(k+n|k) = \mathbf{C}[\mathbf{A}^n x(k) + \sum_{i=1}^n \mathbf{A}^{i-1} \mathbf{B}u(k+n-i|k)] \quad (4.19.)$$

c) formiranje kriterijske funkcije

Kriterijskom funkcijom se smanjuje odstupanje izlaza y na predikcijskom horizontu od željenog izlaza w , te istodobno smanjuje i promjena upravljačkog signala potrebna da bi se ostvarilo željeno slijeđenje.

Kriterijska funkcija J obično ima oblik prema [122]:

$$\begin{aligned} J(\mathbf{y}_k, \mathbf{u}_k, \mathbf{w}, \Delta u(k|k), \Delta u(k+1|k), \dots, \Delta u(k+N_U-1|k)) = \\ = \sum_{j=N_1}^{N_2} \delta(j) [y(k+j|k) - w(k+j)]^2 + \sum_{j=1}^{N_U} \lambda(j) [\Delta u(k+j-1|k)]^2 \end{aligned} \quad (4.20.)$$

gdje su:

$\mathbf{y}_k, \mathbf{u}_k$ – vektori koji opisuju trenutno stanje procesa, u trenutku k ,

\mathbf{w} – vektor točaka na željenoj trajektoriji izlaza (na predikcijskom horizontu),

$k+N_1$ – trenutak u budućnosti od kojeg počinje smanjivanje odstupanja izlaza od referentne trajektorije,

$k+N_2$ – trenutak u budućnosti do kojeg se smanjuje odstupanje izlaza od željene trajektorije,

$\delta(j)$ – težinski faktor kojom se smanjuje odstupanje vektora y od vektora w u trenutku $k+j$ u budućnosti,

$\lambda(j)$ – težinski faktor kojom se smanjuje promjena upravljačkog signala u trenutku $k+j$ u budućnosti,

Trebalo bi reći prema [122], da su ipak realno, upravljačke veličine svih procesa ograničene. Kod izlaznih veličina procesa potrebno bi ih bilo također ograničiti iz razloga efikasnosti, sigurnosti i dugovječnosti procesa.

d) računanje predikcijskog vektora izlaza regulatora

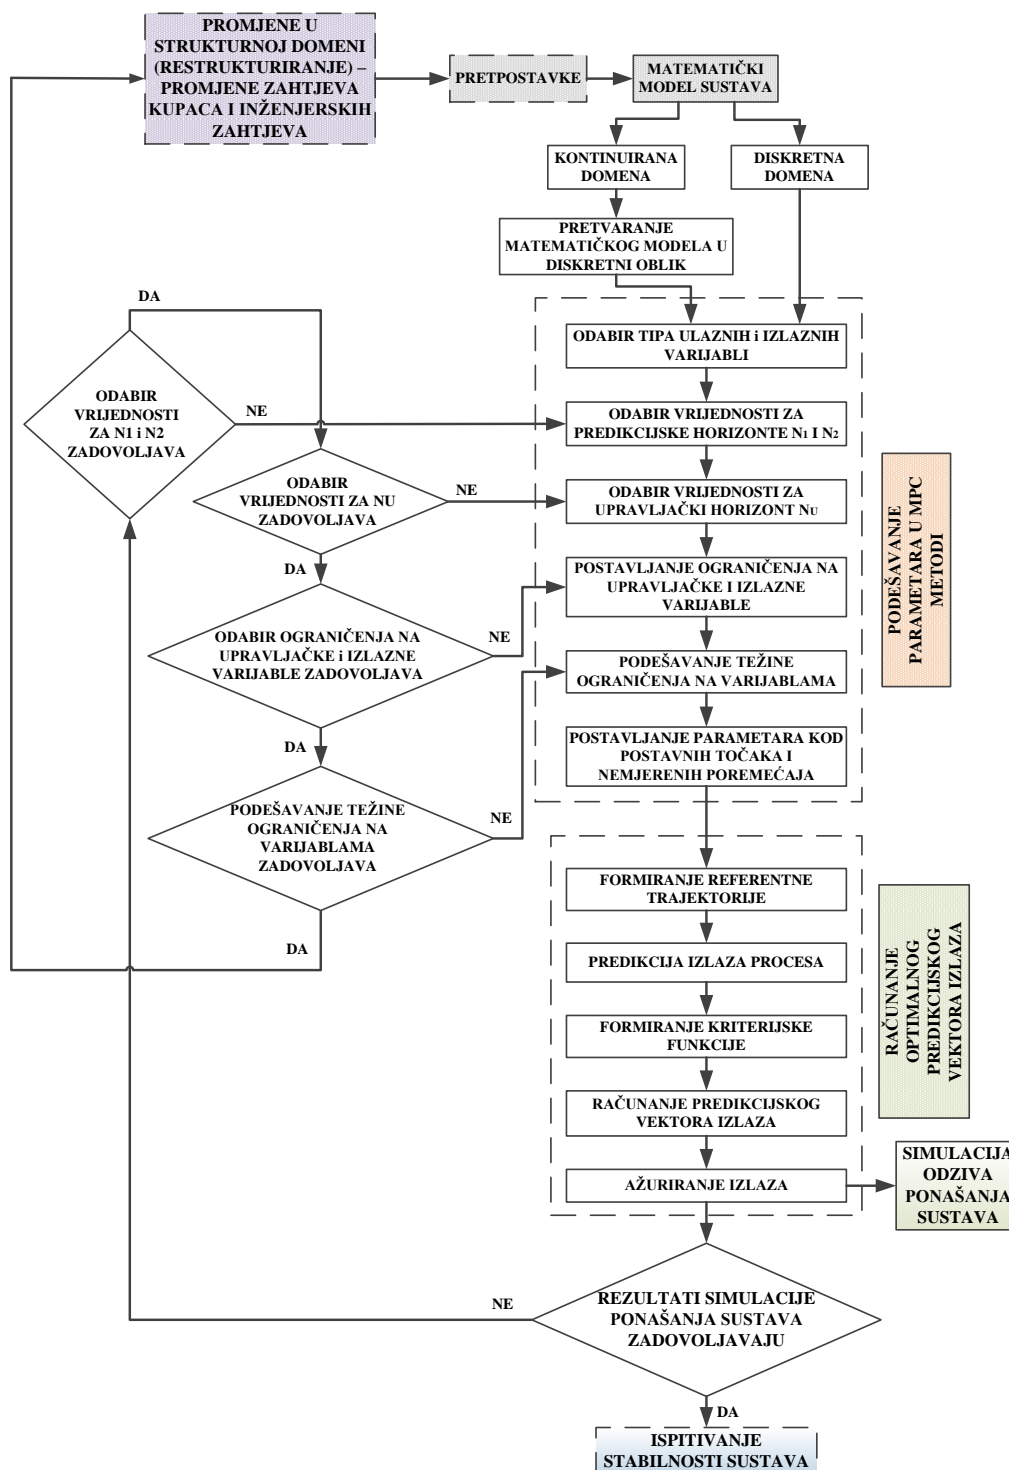
Računa se optimalni predikcijski vektor izlaza regulatora $\hat{\mathbf{u}}_{opt}$, kojim se minimizira kriterijska funkcija J opisana u koraku c:

$$\frac{\partial J(\mathbf{w}, \hat{\mathbf{y}}, \hat{\mathbf{u}})}{\partial \hat{\mathbf{u}}} \bigg|_{\hat{\mathbf{u}}=\hat{\mathbf{u}}_{opt}} = 0 \quad (4.21.)$$

Rješenje problema minimizacije dobiva se iteracijskim postupkom u više koraka. Bitno je naglasiti da postoji razlika u računanju, kad se radi bez ograničenja, te sa ograničenjima izlaznih veličina procesa.

e) ažuriranje izlaza regulatora

Prvi element proračunatog optimalnog predikcijskog vektora izlaza regulatora šalje se na njegov izlaz. Ostali elementi vektora se ne koriste već se u trenutku $t = (k+1)T$ cijeli postupak ponavlja.



Slika 4.6. Algoritam MPC metode za obje ponašajne domene (kontinuiranu i diskretnu)

Pokretanjem simulacije dobivaju se odzivi sustava. U slučaju dobivenih zadovoljavajućih rezultata simulacije ponašanja sustava, rezultati se grafički prikazuju prikazom odziva ulaznih i izlaznih varijabli. U suprotnom slučaju, ako se ne dobiju zadovoljavajući rezultati, vrše se korekcije putem povratne petlje. Prvo se vrše korekcije na postavljenim parametrima u MPC metodi (predikcijski horizonti N_1 i N_2 , upravljački horizont N_U), te ograničenja na upravljačkim i izlaznim varijablama i postavljanje težine ograničenja na varijablama.

Ako se ni s tim promjenama ne dobiju zadovoljavajući rezultati simulacije, potrebno je izvršiti promjene u strukturnoj domeni sustava (restrukturiranje – uključivanjem novih ili uklanjanjem postojećih podsustava ili modula) putem povratne veze.

Na slici 4.6. prikazan je algoritam MPC metode dijagramom toka sa pojedinim koracima unutar te operacije.

4.5. Ispitivanje stabilnosti sustava

Algoritam ispitivanja stabilnosti sustava (za kontinuiranu i diskretnu domenu) prikazan je dijagramom toka na slici 4.7. Na osnovu prethodno opisane operacije kreiranja matematičkog modela sustava (vidi točku 4.3.), u prostoru stanju, kreće se sa ispitivanjem stabilnosti sustava. U nastavku je opisan algoritam za sustave koji su izrazito linearni, te nelinearne sustave koji se daju linearizirati. Sve je to dano za skupinu vremenski invarijantnih (LTI) sustava. U nastavku slijedi opis algoritma ispitivanja stabilnosti kontinuiranih i diskretnih sustava.

4.5.1. Ispitivanje stabilnosti kontinuiranih sustava

Funkcija Ljapunova se kod linearnih sustava i to vremenski nepromjenjivih, kreira na slijedeći način (prema [72], [80]). Promatramo linearni nepobuđeni sustav, vremenski invarijantan, kojeg možemo opisati sa slijedećom jednačinom:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\mathbf{x}(t); \mathbf{x} \in R^n \quad (4.22.)$$

Za takav sustav funkciju Ljapunova možemo tražiti u obliku kvadratične funkcije:

$$V = \mathbf{x}^T \mathbf{P} \mathbf{x} \quad (4.23.),$$

gdje je:

\mathbf{P} – simetrična pozitivno određena matrica

Da bi takav sustav bio stabilan, derivacija Ljapunovljeve funkcije, mora biti negativno određena, tj.

$$\dot{V} = -\mathbf{x}^T \mathbf{Q} \mathbf{x} \quad (4.24.),$$

gdje je:

\mathbf{Q} – neka simetrična pozitivno određena matrica.

Ako jednadžbu (4.23.) deriviramo po vremenu, dobivamo:

$$\dot{V} = \dot{\mathbf{x}}^T \mathbf{P} \mathbf{x} + \mathbf{x}^T \mathbf{P} \dot{\mathbf{x}} \quad (4.25.)$$

Izjednačivši jednadžbe (4.24.) i (4.25.), možemo pisati:

$$\dot{V} = \dot{\mathbf{x}}^T \mathbf{P} \mathbf{x} + \mathbf{x}^T \mathbf{P} \dot{\mathbf{x}} = -\dot{\mathbf{x}}^T \mathbf{Q} \mathbf{x} \quad (4.26.)$$

Ako uvrstimo jednadžbu (4.22.) u (4.26.), te to raspišemo, dobiti ćemo:

$$\mathbf{x}^T \mathbf{A}^T \mathbf{P} \mathbf{x} + \mathbf{x}^T \mathbf{P} \mathbf{A} \mathbf{x} = \mathbf{x}^T (\mathbf{A}^T \mathbf{P} + \mathbf{P} \mathbf{A}) \mathbf{x} = -\mathbf{x}^T \mathbf{Q} \mathbf{x} \quad (4.27.)$$

Iz čega dobivamo:

$$\mathbf{A}^T \mathbf{P} + \mathbf{P} \mathbf{A} = -\mathbf{Q} \quad (4.28.),$$

koja se naziva *Ljapunovljeva matrična jednadžba*, gdje su: \mathbf{P} i \mathbf{Q} pozitivno određene simetrične matrice.

Ispitivanje stabilnosti provodi se na tako da se prvo odabere simetrična matrica \mathbf{Q} , koja mora biti pozitivno određena (obično se odabire da je to pozitivna matrica). Zatim se iz jednadžbe (4.28.) izračuna simetrična matrica \mathbf{P} . Ako je ona pozitivna tada je sustav globalno asimptotski stabilan u smislu Ljapunova.

Sad se mogu primijeniti uvjeti na nepobuđeni sustav za lokalnu i globalnu asimptotsku stabilnost, te provesti ispitivanje stabilnosti.

4.5.2. Ispitivanje stabilnosti diskretnih sustava

Kod diskretnih sustava ispitivanje stabilnosti izravnom metodom Ljapunova provodi se po analogiji maloprije opisanog postupka za kontinuirane sustave [72]. Osnovna ideja je da se uvede poopćena funkcija Ljapunova (skalarna funkcija energije), koja je pozitivna u cijelom prostoru stanja, osim u ishodištu u kojem je jednaka nuli.

Ravnotežno stanje je stabilno, ako se može pokazati da se funkcija Ljapunova smanjuje duž trajektorija stanja sustava.

Tada se za vremenski nepromjenjivi diskretni sustav može pisati:

$$f(x_k) = x(k+1) = \Phi x(k) \quad (4.29.)$$

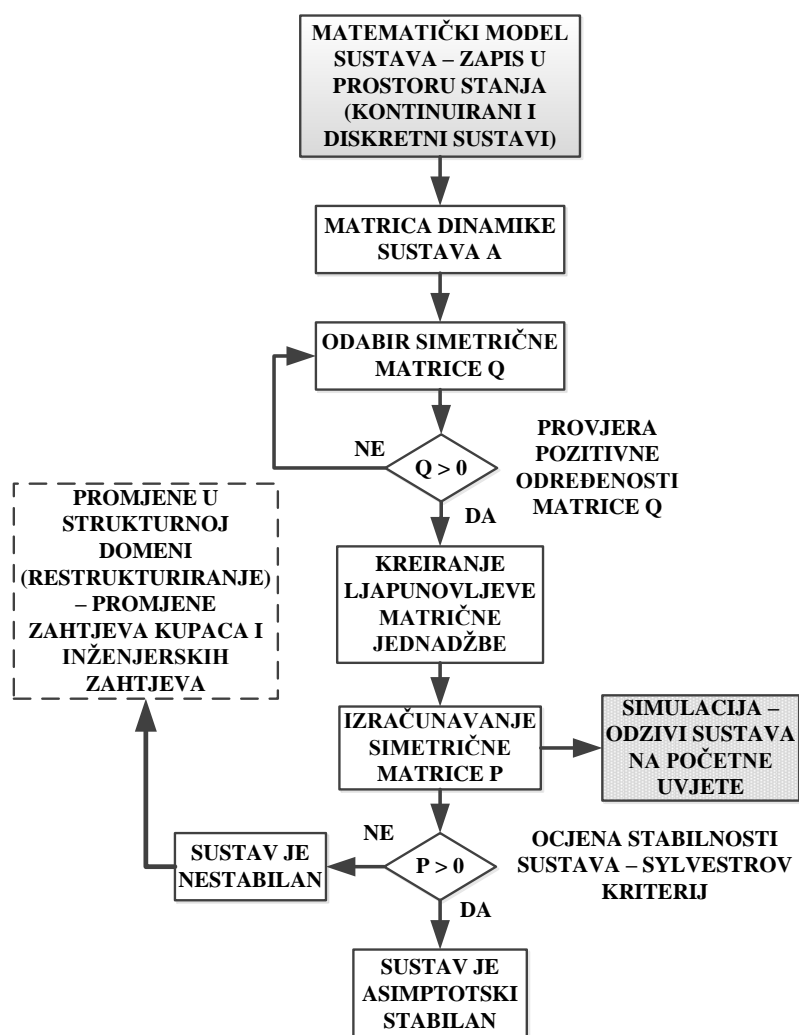
Derivacija Ljapunovljeve funkcije kod diskretnih sustava prikazuje se s prvom diferencijom funkcije $\Delta V[x(k)]$ koja je dana sa:

$$\frac{\Delta V(x(k))}{\Delta t} = \frac{V[x(k+1)] - V[x(k)]}{T} \quad (4.30.)$$

Zbog jednostavnosti može se uzeti da je $T = 1$. Funkciju Ljapunova opisujemo pozitivno određenom kvadratičnom funkcijom:

$$V[x(k)] = x^T(k) \cdot P \cdot x(k) \quad (4.31.)$$

Funkcija $V[x(k)]$ biti će pozitivno određena ,ako je simetrična matrica P pozitivno određena (to možemo provjeriti npr. Sylvestrovim kriterijem).



Slika 4.7. Algoritam ispitivanja stabilnosti sustava za obje ponašajne domene (kontinuiranu i diskretnu)

Također diferencija funkcije $\Delta V[x(k)]$ treba biti negativno određena, tj.:

$$\Delta V[x(k)] = -x^T(k) \cdot Q \cdot x(k) < 0 \quad (4.32.)$$

Također proizlazi da i matrica Q mora biti pozitivno određena:

$$-Q = \Phi^T \cdot P \cdot \Phi - P \quad (4.33.)$$

Kad analiziramo asimptotsku stabilnost diskretnih sustava, potrebno je da matricu Q odaberemo tako da bude pozitivno određena, te se tada određuje matrica P . Ako je ona pozitivno određena sustav je asimptotski stabilan.

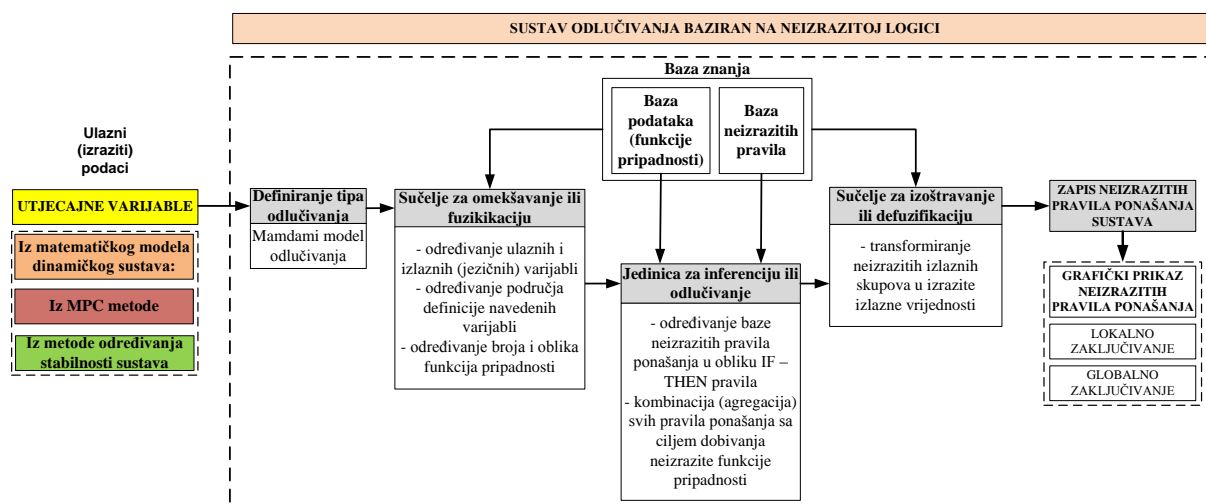
U slučaju dobivanja nestabilnosti sustava, potrebno je izvršiti promjene u strukturnoj domeni sustava (restrukturiranje – uključivanjem novih ili uklanjanjem postojećih podsustava ili modula) putem povratne veze. Prije toga potrebno je izvršiti promjene zahtjeva kupaca i inženjerskih zahtjeva.

4.6. Sustav odlučivanja baziran na neizrazitoj logici odlučivanja

Shema sustava odlučivanja baziranog na neizrazitoj logici prikazana je na slici 4.8. U nastavku slijedi kratki opis principa rada sustava.

Ulazni podaci u sustav su utjecajne varijable, dobivene iz matematičkog modela dinamičkog sustava, MPC metode i ispitivanja stabilnosti sustava.

Nakon definiranja modela odlučivanja na neizrazitoj logici (u ovom slučaju je to Mamdani model), kreće se s pojedinim postupcima u sustavu, kao što je to opisano u nastavku.



Slika 4.8. Shema sustava odlučivanja baziranog na neizrazitoj logici sa opisima pojedinih postupaka unutar njega

Osnovu rada sustava odlučivanja baziranog na neizrazitoj logici slijedeći postupci (dijelovi sustava) ([113] - [115]):

1. *Omekšavanje ili fazifikacija* (engl. *Fuzzyfication*),
2. *Inferencija ili proces neizrazitog odlučivanja*,
3. *Izoštavanje ili defazifikacija* (engl. *Defuzzyfication*)

Svih navedeni postupci su u interakciji i mogu međusobno izmjenjivati informacije. Ti dijelovi sustava za odlučivanje su dinamički povezani, na način da se promjena u jednom od njih, automatski registrira i u ostalima.

4.6.1. Omekšavanje ili fazifikacija

U postupku omekšavanja ili fazifikacije ([114], [115]) se na temelju definiranih utjecajnih varijabli, odabiru ulazne varijable, kao i izlazna varijabla (sa svojim nazivima).

Za svaku varijablu definira se broj jezičnih vrijednosti, kao i područje definicije navedenih varijabli. Za svaku varijablu određuje se njeno područje definicije. Uz to određuje se broj i oblik funkcija pripadnosti, koje prekrivaju područje definicije pojedinih jezičnih varijabli.

Funkcija pripadnosti (engl. *Membership function (MF)*) ([114], [115]) je krivulja koja definira stupanj pripadnosti svake točke u ulaznom prostoru (engl. *Universe of discourse*). Ona preslikava točku u ulaznom prostoru u pripadnu vrijednost između vrijednosti 0 i 1. To je u biti i jedini uvjet koji funkcija pripadnosti mora realno zadovoljiti. Pošto je neizraziti skup proširenje klasičnog skupa, možemo ga zapisati na slijedeći način. Ako je X ulazni prostor i njegove elemente obilježavamo sa x , tada je neizraziti skup definiran kao skup uređenih parova oblika:

$$A = \{x, \mu_A(x) | x \in X\} \quad (4.34.)$$

gdje je:

$\mu_A(x)$ – funkcija pripadnosti od x u neizrazitom skupu A

Funkcije pripadnosti neizrazitih skupova su uvijek normalizirane, što znači da je maksimalna vrijednost funkcije pripadnosti jednaka 1. Izbor oblika funkcija pripadnosti pojedinih neizrazitih skupova je subjektivan i ovisi o razmatranom problemu.

Postoji više funkcija omekšavanja kod Mamdami tipa logike, od kojih se najčešće koristi metoda težišta (engl. *Center of area method* ili *Center of gravity method*) [115].

Jezična varijabla (engl. *Linguistic variable*) ([114], [115]) je varijabla koja kao vrijednosti poprima riječi ili rečenice. Jezična varijabla se zapisuje na slijedeći način:

$$[x, T(x), X, M], \quad (4.35.)$$

gdje je:

x – ime jezične varijable,

$T(x)$ – prostor jezičnih vrijednosti koje varijabla x može poprimiti, odnosno prostor neizrazitih skupova definiranih nad područjem X ,

X – kvantitativno područje razmatranja (može biti kontinuirano ili diskretno) varijable x nad kojom ona poprima lingvističke vrijednosti,

M – semantička funkcija (semantičko pravilo), koje povezuje prostor $T(x)$ s područjem X .

4.6.2. Inferencija ili proces neizrazitog odlučivanja

Neizrazita pravila (engl. *Fuzzy logic rules*) ([114], [115]), kreiraju se prema određenim ulaznim varijablama i izlaznoj varijabli. Kreiranjem pravila ponašanja stvaramo (određujemo) bazu pravila ponašanja u obliku neizrazitih IF–THEN pravila.

Za svako neizrazito pravilo odabire se logički operator (engl. *Connection*), te težina neizrazitog pravila (engl. *Weight*). Poznati logički operatori su: AND, OR i NOT. Definirani su na slijedeći način. Operator AND kao neizraziti presjek ili konjunkcija, operator OR kao neizrazita unija ili disjunkcija i operator NOT kao komplement. Ako pretpostavimo da imamo slijedeće neizrazite skupove ([114], [115]):

$$A = \{x, \mu_A(x) | x \in X\} \text{ i } B = \{x, \mu_B(x) | x \in X\}. \quad (4.36.)$$

Neizraziti presjek ili konjunkcija (engl. *Fuzzy intersection or conjunction*) dvaju neizrazitih skupova A i B općenito se specificira kao binarno preslikavanje T , koje agregira dvije funkcije pripadnosti kako slijedi:

$$\mu_{A \cap B}(x) = T(\mu_A(x), \mu_B(x)) = \min(\mu_A(x), \mu_B(x)) \quad (4.37.)$$

Preslikavanje T je predstavljeno operatorom T norme. Konjunkcija se još naziva i *neizrazito logičko množenje* [115].

Neizrazita unija ili disjunkcija (engl. *Fuzzy union or disjunction*) dvaju neizrazitih skupova A i B obično se specificira kao binarno preslikavanje S :

$$\mu_{A \cup B}(x) = S(\mu_A(x), \mu_B(x)) = \max(\mu_A(x), \mu_B(x)) \quad (4.38.)$$

Kao i kod prethodnog operatora i ovdje je preslikavanje predstavljeno operatorom S norme. Disjunkcija se još naziva i *neizrazito logičko zbrajanje*.

Neizraziti komplement ili neizrazita negacija (engl. *Fuzzy complement*) definira se kao:

$$\bar{p} = 1 - \mu_A(x) \quad (4.39.)$$

Neizrazita uvjetna propozicija ili implikacija, definira se kao stupanj istinitosti $p \rightarrow q$ (*IF p THEN q*):

$$p \rightarrow q = \min\{1, 1 + \mu_B(x) - \mu_A(x)\} \quad (4.40.)$$

ili Mamdamijeva definicija:

$$p \rightarrow q = \min\{\mu_A(x), \mu_B(x)\} \quad (4.41.)$$

Opći oblik neizrazitih pravila (IF–THEN pravila) (na primjeru dviju ulaznih varijabli) po Mamdamiju ([113] - [115], [139]):

$$\text{IF } x \text{ je } A_i \text{ (tip operatora) } y \text{ is } B_j \text{ THEN } u \text{ je } C_{(ij)}, i=1,2,\dots,N; j=1,2,\dots,M; ij=k=1,2,\dots,L \quad (4.42.)$$

Lijeva strana pravila se naziva *premisa* (engl. *Antecedent*), a desna strana pravila *zaključak* (engl. *Consequent*).

Izlazna funkcija pripadnosti dobiva se kao agregacija (kombinacija) navedenih pravila primjenom operatora logičkog zbrajanja \vee :

$$\mu_{agg}(x, y, u) = \bigvee_{i=1}^N \bigvee_{j=1}^M ((p_i \wedge q_j) \rightarrow r_{ij}) \quad (4.43.)$$

4.6.3. Izoštavanje ili defazifikacija

U tom postupku transformiraju se neizraziti izlazni skupovi u izrazite izlazne vrijednosti. Ne postoji jedinstven način defazifikacije, no postoji mnogo metoda od kojih se najčešće koristi metoda težišta (engl. *Center of area method*) ([114], [115]):

$$u_o = \frac{\int u \cdot \mu_{agg}(x, y, u) du}{\int \mu_{agg}(x, y, u) du} \quad (4.44.)$$

Izlazna vrijednost funkcije izrazitih vrijednosti se dobiva:

$$u_o = u_o(x, y) \quad (4.45.)$$

Rezultati izoštavanja ili defazifikacije prikazuju se tablično kao pravila, odnosno grafički pomoću površina.

4.6.4. Lokalno i globalno zaključivanje

Grafički prikaz svih definiranih neizrazitih pravila, sa prikazom njihovih funkcija pripadnosti, nazivamo tzv. lokalnim zaključivanjem. Grafički trodimenzionalni 3D prikaz dviju ulaznih varijabli i izlazne varijable nazivamo tzv. globalnim zaključivanjem ([114], [115]). Za grafički prikaz lokalnog i globalnog zaključivanja, potrebno je imati preglednike.

4.7. Zapis pravila ponašanja sustava

U slučaju zadovoljavajućih pravila ponašanja, ona se mogu zapisati na dva načina: u datoteku ili u radno okruženje editora pravila ponaša pranja. Zapisana pravila ponašanja nam daju zapis ponašanja određene varijante složenog tehničkog sustava (za odabrani skup utjecajnih varijabli) u određenim radnim uvjetima, izložen pri tome neizvjesnim vanjskim utjecajima.

Odabir utjecajnih varijabli je vršen shodno iskustvu konstruktora, koji procjenjuje koje od njih treba odabrati za određeni tip složenog tehničkog sustava.

4.8. Prijenos informacija između pojedinih operacija algoritma

U nastavku se opisuju informacije koje se prenose između pojedinih operacija u algoritmu za razvoj arhitektura složenih tehničkih sustava, predloženog u ovom poglavlju. Prijenos će biti prikazan između pojedinih operacija predloženog algoritma:

- Matrica komponenata (Design Structure Matrix – DSM) se kreira na osnovu predloženih zahtjeva kupaca, odnosno inženjerskih zahtjeva, te uz kataloške podatke o sličnim proizvodima, kod razvoja novog ili poboljšanja postojećeg sustava.
- Iz DSM-a se dobivaju podaci o mogućim podsustavima (modulima). Na osnovu tih podataka o mogućim podsustavima se prema uvedenim pretpostavkama za matematičko modeliranje postavljaju jednačbe za pojedine procese (ili sustav ako ga promatramo u cjelini). Kod složenih sustava, potrebno je matematički modelirati svaki proces u sustavu zasebno. Sustav (proces) se nakon toga zapisuje u prostoru stanja.
- U MPC metodi prvo se kreirani matematički model kontinuirane domene sustava (iz prethodnog koraka), prevodi u diskretni oblik. Uz odabir svih prije navedenih parametara, gleda se da li je moguće ostvariti zadovoljavajuće rezultate simulacije tehničkog sustava (uz podešavanje svih parametara MPC metode).

- U slučaju linearnog sustava, matematički model sustava (procesa) se koristi kod ispitivanja stabilnosti sustava, tj. koristi se njegova matrica dinamike sustava \mathbf{A} .
- U slučaju nelinearnog sustava, koji se ne može svesti na linearni oblik, a da se ne izgube neka od njegovih svojstava dinamičkog ponašanja, potrebno je kod ispitivanja stabilnosti sustava uzeti u obzir zajedno model sustava i kriterijsku funkciju MPC metode i tada ispitivati stabilnost takvog tehničkog sustava.
- Konstruktor na osnovu svog iskustva procjenjuje koje su to utjecajne varijable iz matematičkog modela linearnog sustava (procesa) koje bi trebalo uzeti u obzir kod definiranja neizrazitih pravila ponašanja (kao ulazne varijable).
- Analogno kao i kod linearnog sustava (za nelinearni sustav), konstruktor na osnovu svog iskustva procjenjuje koje su to utjecajne varijable iz MPC metode koje bi trebalo uzeti u obzir kod definiranja neizrazitih pravila ponašanja (kao ulazne varijable).
- Informacija o ispitivanju stabilnosti sustava (nestabilan, asimptotski stabilan ili stabilan) se kasnije koristi kao izlazna varijabla kod kreiranja neizrazitih pravila ponašanja.
- Za određeni sustav (proces) za kojeg se kroz prethodne korake ustanovilo da ima zadovoljavajuće ponašanje (stabilan sustav za većinu ulaznih varijabli), te stabilan kod neizvjesnih radnih uvjeta, može se predložiti za novo razvijenu varijantu tehničkog sustava ili novo poboljšanu varijantu nekog postojećeg tehničkog sustava. U slučaju da sustav nema zadovoljavajuće ponašanje, te je nestabilan u neizvjesnim uvjetima rada, ponavlja se algoritam putem povratnih vezi (kako je to opisano u prethodnim točkama ovog poglavlja) na operaciju restrukturiranja, nakon čega se pojedine operacije algoritma ponavljaju. Algoritam je iterativnog karaktera, tj. potrebno je više koraka iteracije da bismo došli do zadovoljavajućeg rješenja.

4.9. Implikacije na rad

U poglavlju je definiran prijedlog algoritma razvoja arhitektura složenih tehničkih sustava po njegovim pojedinim operacijama. Uz detaljan opis svake operacije algoritma, opisani su i modeli pojedinih metoda u pojedinim operacijama uz dani dijagramski prikaz.

Uz to je na kraju dan i opis prijenosa informacija između pojedinih operacija algoritma.

Kao što se može vidjeti algoritam je iterativnog karaktera, tj. provjerom rezultata simulacije ponašanja sustava, te provjerom njegove stabilnosti, putem povratnih veza možemo podešavati parametre u MPC metodi, provjeru pozitivne određenosti matrice Q kod ispitivanja sustava, te mijenjati podsustave (uključivati ili ih uklanjati) u domeni strukture.

Ono što je velika prednost ovog algoritma je mogućnost simulacije ponašanja sustava tokom vremena, kao i mogućnost uzimanja u obzir poremećajnih varijabli (varijable koje uzrokuju neizvjesno ponašanje) kroz matematički model sustava. Također odabirom pojedinih parametara u MPC metodi možemo mijenjati odzive promatranih varijabli i na taj način utjecati na rezultate simulacije ponašanja sustava. Ponašanje svake varijante tehničkog sustava moguće je zapisati u obliku neizrazitih pravila ponašanja. Poglavlje služi kao dobra teoretska podloga za razumijevanje i kasniju provedbu verifikacije algoritma. Verifikacija algoritma bit će provedena u sljedećem poglavlju na realnim primjerima tehničkih sustava: elektromehaničkog sustava (uređaj za dizanje tereta) i toplinsko – hidrauličnog sustava (klima komora).

VERIFIKACIJA

Poglavlje opisuje verifikaciju algoritma razvoja arhitektura složenih tehničkih sustava (opisanog u prethodnom poglavlju). Verifikacija daje vrednovanje rezultata istraživanja kroz analizu na odabranim realnim primjerima složenih tehničkih sustava. Kao realni primjeri složenih tehničkih sustava odabrani su: elektromehanički sustav (sa elektromotorom, prijenosnikom snage i bubnjem s kukom), koji će biti korišten u brodogradilištu za dizanje tereta, te klima komora, koja će biti korištena u poslovnom objektu za pripremu kondicioniranog zraka. Oba primjera su smisljeno odabrana da se pokaže kako je predloženi algoritam primjenjiv na primjerima sustava koji su po svojoj prirodi procesa izrazito nelinearni (kao što je to u slučaju uređaj za dizanje tereta), kao i na primjeru izrazito linearnih sustava (klima komora). Nelinearni sustav se uvođenjem navedenih pretpostavki, kao i primjenom jedne od metoda linearizacije, može svesti na linearni sustav. U takvom prikazu sustava, on neće izgubiti svoja dinamička svojstva. Verifikacija je u oba slučaja provedena kroz nekoliko koraka iteracije, prikazom svake pojedine operacije predloženog algoritma kroz svaki korak iteracije. Uz to dan je prikaz dobivenih rezultata (prikaz arhitekture sustava u matričnom zapisu pomoću DSM-a, odzivi varijabli u MPC metodi i ispitivanju stabilnosti sustava, te zapis neizrazitih pravila odlučivanja, sa grafičkim prikazom lokalnog i globalnog zaključivanja). Dobiveni rezultati dani su za rad elektromehaničkog sustava, uz djelovanje vjetra za odabrani slučaj opterećenja tereta. Uz to dani su rezultati za zimski princip rada klima komore, pošto niske vanjske temperature najviše utječu na stabilan rad sustava. Također verifikacija je provedena po pojedinim operacijama, kako je to opisano u poglavlju 4. Na kraju svakog koraka iteracije za oba primjera, dan je tablični prikaz dobivenih rezultata koraka algoritma. Verifikacija za oba primjera provedena je i pod neizvjesnim uvjetima

rada. Kod prvog primjera (uređaj za dizanje tereta), to će biti to biti uslijed djelovanja jakih brzina vjetra na teret), dok je to kod drugog primjera (klima komora) uslijed utjecaja niskih vanjskih temperatura.

5.1. Primjena algoritma u razvoju elektromehaničkog sustava

Kao prvi realni primjer tehničkog sustava odabran je elektromehanički sustav (uređaj za dizanje tereta), koji se koristi na granicama za dizanje tereta u brodogradilištima. Sustav je odabran iz razloga, što je to primjer izrazito nelinearnog sustava, koji se metodom linearizacije može prevesti u oblik linearnog sustava. Pri tome za nametnute radne i neizvjesne uvjete, neće izgubiti na svom ponašanju. Sastoji se od prijenosnika snage pogonjenog elektromotorom, te bubnja za dizanje tereta sa čeličnim užetom i zahvatnim sredstvom kukom ([125], [126]). Uređaj je izložen atmosferskim utjecajima, a ispituje se u promjenjivim radnim uvjetima, posebice u neizvjesnim radnim uvjetima prilikom jakih udara vjetra [127].

5.1.1. Korak iteracije 1

1. Opisivanje arhitekture sustava

Početna (inicijalna) arhitektura sustava uređaja za dizanje tereta, kreira se na temelju danih zahtjeva kupaca, te iz njih kreiranih inženjerskih zahtjeva. Uz to koriste se kataloški podaci proizvođača sličnih sustava na osnovu kojih se predlaže početna (inicijalna) arhitektura sustava. Predlaže se sustav uređaja za dizanje sastoji od slijedećih podsustava: trofaznog asinkronog elektromotora, pogonskog i gonjenog vratila, spojki na pogonskom i gonjenom vratilu, ležajeva, jednostupanjskog prijenosnika snage, bubnja za dizanje, čeličnog užeta i kuke za prihvat tereta (prikazano na slici 5.1.).

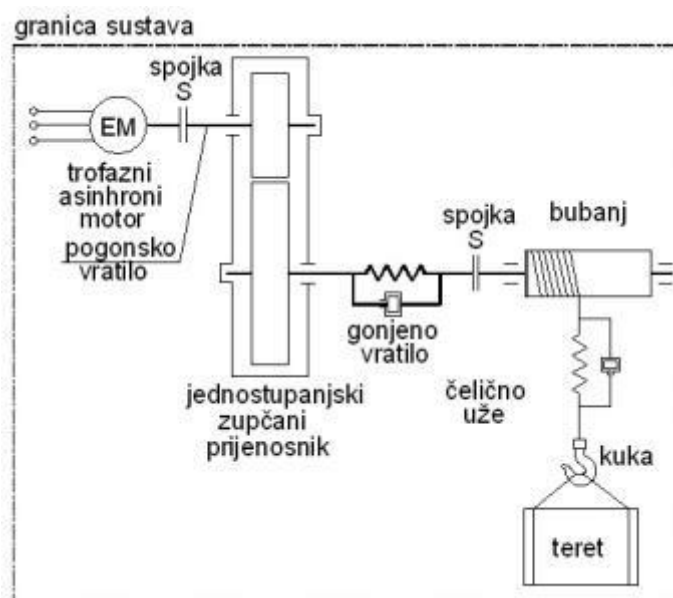
Zahtjevi kupaca su slijedeći:

- uređaj mora biti izveden za vanjsku ugradnju,
- uređaj mora moći raditi u promjenjivim vanjskim uvjetima rada,
- uređaj mora biti otporan na atmosferske utjecaje (vodu, kišu, snijeg, led, zrak i udare vjetra),
- uređaj je namijenjen za ugradnju na mosne granike u brodogradilištima,
- uređajem se mora moći automatski upravljati.

Inženjerski zahtjevi su slijedeći:

- uređaj je smješten u obalnom pojasu Republike Hrvatske,
- uređaj mora moći raditi pri velikim brzinama vjetra: do 100 km/h (III zona) [125],
- uređaju se mora osigurati neprekidni priključak na električnu energiju 3x220 V, 50 Hz,
- uređaj mora imati osiguran isprekidani način rada,
- uređaj mora imati mogućnost dizanja i spuštanja tereta,
- elektromotor za pogon uređaja mora moći raditi sa promjenjivim brzinama vrtnje,
- uređaj je namijenjen za dizanje manjih tereta do 10 t,
- dizanje i spuštanje tereta mora biti pomoću zahvatnog sredstva kuke,
- uređaj mora biti otporan na udare i vibracije,
- mora biti osigurana stabilnost uređaja u radu.

Prema opisanim operacijama algoritma (u prethodnom poglavlju), prvo je matricom komponenata DSM-om ([27], [119]) opisana predložena arhitektura sustava, te su analizom dobiveni mogući podsustavi. Dobiveni rezultati iz DSM-a prikazani su na slici 5.5. a. U tu svrhu korišten je računalni program *LOOME* [128]. Prema shematskom prikazu na slici 5.2. kreće se u kreiranje matematičkog modela ponašanja sustava.



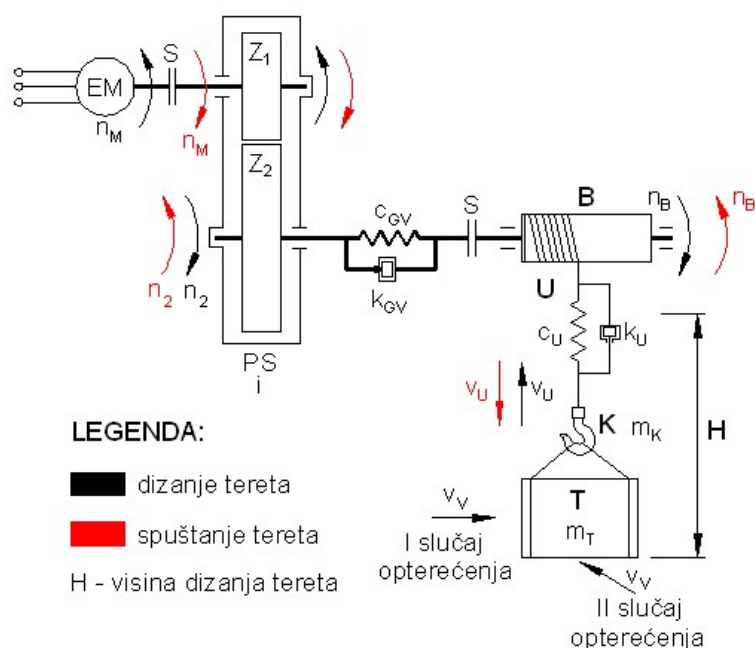
Slika 5.1. Početna (inicijalna) arhitektura sustava uređaja za dizanje tereta (korak iteracije 1)

2. Kreiranje matematičkog modela ponašanja sustava

Početne pretpostavke koje uvodimo kod modeliranja matematičkog modela ponašanja pojedinih podsustava uređaja za dizanje tereta su sljedeće [127]:

- zanemaruju se svi gubici u ležajevima, zupčanicima i spojkama,
- zanemaruju se svi otpori vožnje uređaja po tračnicama,
- zanemaruju se svi gubici u mehanizmu za dizanje, tokom radnog i kočnog stanja,
- otpor koji se uzima u razmatranje je otpor uslijed djelovanja vjetra,
- zbog kompaktne izvedbe trofaznog asinkronog motora i prijenosnika snage sa spojkom ([126], [129], [130]), pretpostavlja se da je pogonsko vratilo izvedeno kao idealno kruto tijelo,
- pretpostavlja se da je gonjeno vratilo i čelično uže izvedeno kao elastično tijelo,
- pretpostavlja se da je teret pravokutnog oblika, volumena $V=abc$ [m³],
- pretpostavlja se direktno dizanje/ spuštanje tereta pomoću bubnja i zahvatnog sredstva čelične kuke,
- pretpostavlja se pogonska grupa uređaja 2 (prema [125]),
- zanemaruje se masa užeta u odnosu na masu kuke i tereta, jer je odnos $\frac{m_K+m_T}{m_u} \cong 20 \div 200$,
- u sustavu se pretpostavljaju male vibracije [131].

Kao mogućnost neočekivanih uvjeta rada, uzet je u obzir otpor uslijed naleta vjetra. Pošto se pretpostavlja da će uređaj biti montiran na graniku u obalnoj zoni Republike Hrvatske, računa se III zona utjecaja prema brzini vjetra [125].



Slika 5.2. Shematski prikaz sa oznakama pojedinih podsustava (korak iteracije 1)

U matematičkom modelu ponašanja se kreiraju diferencijalne jednačbe gibanja mehanizma ([125], [126], [132] - [134]). Jednačbe se kreiraju pomoću Lagrangeovih jednačbi druge vrste za mehaničke sustave u najopćenitijem obliku (sa s stupnjeva slobode gibanja) [131]:

$$\frac{d}{dt} \left(\frac{\partial E_k}{\partial \dot{q}_j} \right) - \frac{\partial E_k}{\partial q_j} + \frac{\partial E_p}{\partial q_j} + \frac{\partial \Phi}{\partial \dot{q}_j} = Q_j, j=1, 2, \dots, s \quad (5.1.),$$

gdje su:

E_k [J] – kinetička energija,

E_p [J] – potencijalna energija,

Φ [J] – Rayleigh-ova disipacijska energija,

q_j – poopćena koordinata,

\dot{q}_j – brzina poopćene koordinate,

Q_j [N] – poopćena sila.

Poopćene koordinate su: $\dot{\varphi}_0$ [rad/s] – kutna brzina elektromotora, $\dot{\varphi}_5$ [rad/s] – kutna brzina bubnja za dizanje tereta, \dot{x} [m/s] – brzina produljenja užeta i $\dot{\varphi}_6$ [rad/s] – kutna brzina užeta.

Prvo se za cjelokupni sustav postavlja kinetička energija:

$$E_k = \frac{1}{2} \left[(J_0 + J_1) + J_2 \cdot \left(\frac{1}{i} \right)^2 \right] \cdot \dot{\varphi}_0 + \frac{1}{2} J_5 \dot{\varphi}_5^2 + \frac{1}{2} m_{uk} [(\dot{v} + \dot{\varphi}_5^2 r_B)^2 + (l_1 + \varphi_5 r_B + x_u)^2 \dot{\varphi}_6^2] \quad (5.2.)$$

gdje su:

J_0 [kgm²] – dinamički moment inercije elektromotora, računa se prema formuli [135]:

$J_0 = \frac{1}{2} m_0 r_0^2$, gdje se vrijednosti: m_0 [kg] – masa elektromotora i r_0 [m] – radijus elektromotora, odabiru se iz kataloga proizvođača ([129], [130])

J_1 [kgm²] – dinamički moment inercije zupčanika 1, računa se prema formuli:

$J_1 = \frac{1}{2} m_1 r_1^2$, gdje se vrijednosti za masu zupčanika 1, računaju približno prema formuli:

$$m_1 = \rho \cdot V_1 = \rho \cdot \frac{D_1^2}{4} \cdot h_1 \text{ [kg]} \quad (5.3.)$$

J_2 [kgm²] – dinamički moment inercije zupčanika 2, računa se prema formuli [135]:

$J_2 = \frac{1}{2} m_2 r_2^2$, gdje se vrijednosti za masu zupčanika 2, također računaju približno prema formuli:

$$m_2 = \rho \cdot V_2 = \rho \cdot \frac{D_2^2}{4} \cdot h_2 \text{ [kg]} \quad (5.4.)$$

i [-] – ukupni prijenosni omjer u prijenosniku snage ([132], [133]), varira se prema zadanom intervalu parametara (prema tablici 5.1.),

$\dot{\varphi}_0$ [rad/s] – kutna brzina elektromotora, varijabla stanja,

$\dot{\varphi}_5$ [rad/s] – kutna brzina bubnja za dizanje tereta, varijabla stanja,

J_5 [kgm²] – dinamički moment inercije bubnja, računa se prema formuli [135]:

$J_5 = \frac{1}{2} m_5 r_B^2$, gdje se vrijednosti za masu bubnja, također računaju približno prema formuli:

$$m_5 = \rho \cdot V_5 = \rho \cdot \frac{D_5^2}{4} \cdot h_5 \text{ [kg]} \quad (5.5.)$$

D_B [m] – promjer bubnja za dizanje tereta, odabire se prema ([125], [126]),

r_B [m] – polumjer bubnja, računa se prema izrazu: $r_B = \frac{D_B}{2}$

$$m_{uk} = m_K + m_T \quad (5.6.)$$

m_{uk} [kg] – ukupna masa,

gdje su:

m_K [kg] – masa kuke – odabire se prema tablici 2.7. iz [126], a prema odabranom broju kuke,

m_T [kg] – masa tereta – varira se prema zadanom intervalu parametara (prema tablici 5.1.),

$\dot{\varphi}_6$ [rad/s] – kutna brzina užeta, varijabla stanja,

x_u [m] – produljenje užeta,

l_1 [m] – početna duljina užeta.

Nakon toga definira se potencijalna energija cjelokupnog sustava:

$$E_p = \frac{1}{2} c_{GV} [\varphi_5 - \left(\frac{1}{i}\right) \varphi_0]^2 - m_{uk} g (l_1 + \varphi_5 r_B + x_u) \cos \varphi_6 + \frac{1}{2} c_u x_u^2 \quad (5.7.),$$

gdje su:


c_{GV} [N/m] – torzijska krutost gonjenog vratila, računa se prema formuli:

$$c_{GV} = \frac{G I_P}{l_{GV}} \quad (5.8.),$$

G [Pa] – modul smicanja gonjenog vratila, odabire se prema [135],

I_P [m⁴] – polarni moment inercije, računa se prema [135],

l_{GV} [m] – duljina gonjenog vratila,



Slika 5.3. Shematski prikaz podsustava 3 sa oznakama (korak iteracije 1)

c_u [N/m] – krutost užeta, računa se prema formuli:

$$c_u = \frac{A_u E_u}{l_1 + \varphi_5 r_B} \quad (5.9.),$$

A_u [m²] – površina poprečnog presjeka užeta, odabire se za zadani promjer užeta prema ([125], [126]),

E_u [Pa] – modul elastičnosti užeta; odabire se prema ([125], [126]).

Na kraju se definira disipacijska ili Rayleigh-ova energija cjelokupnog sustava:

$$\Phi = \frac{1}{2}k_{GV}[\dot{\varphi}_5 - \left(\frac{1}{i}\right)\dot{\varphi}_0]^2 + \frac{1}{2}k_u\dot{x}_u^2 \quad (5.10.),$$

gdje su:

k_{GV} [Ns/m] – koeficijent viskoznog prigušenja gonjenog vratila,

k_u [Ns/m] – koeficijent viskoznog prigušenja užeta,

\dot{x}_u [m/s] – brzina produljenja užeta, varijabla stanja.

Poopćene sile u sustavu kreiramo pomoću virtualnih radova:

$$Q_0 = \frac{\delta W}{\delta \varphi_0} = \frac{M_{EM}\delta \varphi_0}{\delta \varphi_0} = M_{EM} \quad (5.11.),$$

$$Q_5 = \frac{\delta W}{\delta \varphi_5} = \frac{F_V\delta \varphi_5 r_B \sin \varphi_6}{\delta \varphi_5} = F_V r_B \sin \varphi_6 \quad (5.12.),$$

$$Q_x = \frac{\delta W}{\delta \varphi_x} = \frac{F_V\delta \varphi_x \sin \varphi_6}{\delta \varphi_x} = F_V \sin \varphi_6 \quad (5.13.),$$

$$Q_6 = \frac{\delta W}{\delta \varphi_6} = \frac{F_V(l_1 + \varphi_5 r_B + x)\delta \varphi_6 \cos \varphi_6}{\delta \varphi_6} = F_V(l_1 + \varphi_5 r_B + v)\cos \varphi_6 \quad (5.14.),$$

gdje su:

M_{EM} [Nm] – moment elektromotora, odabire se iz kataloga proizvođača ([129], [130]),

F_V [N] – sila vjetra – otpor vjetra uzima se prema važećim normama HRN M.D1.050, DIN 1055 za dobavna sredstva koja rade na otvorenom prostoru ([125], [126]), računa se prema izrazu:

$$F_V = cqA \quad (5.15.),$$

gdje su:

c [-] – koeficijent zapreke, ovisi o obliku plohe na koju nalijeće vjetar, kako je teret pretpostavljen da je pravokutnog oblika, tada on iznosi $c \cong 1,2$ (prema [125]),

q [N/m²] – pretlak zastoja, računa se prema izrazu:

$$q \cong \frac{v_V^2}{21} \quad (5.16.)$$

v_V – brzina vjetra – varira se prema zadanom intervalu parametara (prema tablici 5.1. [125]) – u jednadžbu (5.16.) se uvrštava u mjernim jedinicama [km/h]

A [m²] – površina tereta na koju djeluje vjetar, pošto je pretpostavljen teret pravokutnog oblika, računa se kao (uzima se slučaj opterećenja II zbog veće površine poprečnog presjeka – prikazano na slici 5.3.):

$$A = ab \quad (5.17.).$$

Kako se u sustavu pretpostavljaju male vibracije [131], tada se može uzeti da je:

$$\sin\varphi_6 \approx \varphi_6 \quad (5.18.),$$

$$\cos\varphi_6 \approx 1 \quad (5.19.),$$

Stoga, se jednadžbe ((5.7.), (5.12.) – (5.14.)), mogu pisati u modificiranom obliku:

$$E_p = \frac{1}{2} c_{GV} [\varphi_5 - \left(\frac{1}{i}\right) \varphi_0]^2 - m_{uk} g (l_1 + \varphi_5 r_B + v) + \frac{1}{2} c_u x_u^2 \quad (5.20.),$$

$$Q_5 = \frac{\delta W}{\delta \varphi_5} = \frac{F_V \delta \varphi_5 r_B \sin \varphi_6}{\delta \varphi_5} = F_V r_B \varphi_6 \quad (5.21.),$$

$$Q_x = \frac{\delta W}{\delta \varphi_x} = \frac{F_V \delta \varphi_x \sin \varphi_6}{\delta \varphi_x} = F_V r_B \varphi_6 \quad (5.22.),$$

$$Q_6 = \frac{\delta W}{\delta \varphi_6} = \frac{F_V (l_1 + \varphi_5 r_B + x_u) \delta \varphi_6 \cos \varphi_6}{\delta \varphi_6} = F_V (l_1 + \varphi_5 r_B + x_u) \quad (5.23.),$$

Derivacijom izraza za kinetičku, potencijalnu i disipacijsku energiju po poopćenim koordinatama φ_0 , φ_5 , x i φ_6 , te po derivacijama poopćenih koordinata dobivaju se slijedeći izrazi. Pritom se dotične jednadžbe lineariziraju, uz pretpostavku malih vibracija.

$$\left[(J_0 + J_1) + J_2 \cdot \left(\frac{1}{i}\right)^2 \right] \cdot \ddot{\varphi}_0 - c_{GV} \left[\varphi_5 - \left(\frac{1}{i}\right)^2 \varphi_0 \right] - k_{GV} \left[\dot{\varphi}_5 - \left(\frac{1}{i}\right) \dot{\varphi}_0 \right] \left(\frac{1}{i}\right) = M_{EM} \quad (5.24.),$$

$$[J_5 + m_{uk} r_B^2] \ddot{\varphi}_5 + m_{uk} r_B (\varphi_5 r_B + x_u + \varphi_6 l_1) + c_{GV} \left[\varphi_5 - \left(\frac{1}{i}\right)^2 \varphi_0 \right] + \frac{A_u E_u r_B}{2} (l_1 + \varphi_5 r_B + x_u l_1) - m_{uk} r_B g + k_{GV} \left[\dot{\varphi}_5 - \left(\frac{1}{i}\right) \dot{\varphi}_0 \right] = F_V r_B \quad (5.25.),$$

$$m_{uk} \ddot{x}_u + m_{uk} \ddot{\varphi}_5 r_B - m_{uk} g (l_1 + \varphi_5 r_B + 1) + A_u E_u x_u l_1 + k_u \dot{x}_u = F_V \varphi_6 \quad (5.26.),$$

$$2 \ddot{\varphi}_6 l_1^2 + m_{uk} g \varphi_6 l_1 = F_V (l_1 + \varphi_5 r_B + x_u) \quad (5.27.).$$

U jednadžbama ((5.24.) – (5.27.)) treba uzeti u obzir upravljačke varijable u stacionarnom stanju, te tada te jednadžbe poprimaju svoj konačni oblik:

$$\left[(J_0 + J_1) + J_2 \cdot \left(\frac{1}{i}\right)^2 \right] \cdot \ddot{\varphi}_0 - c_{GV} \left[\varphi_5 - \left(\frac{1}{i}\right)^2 \varphi_0 \right] - k_{GV} \left[\dot{\varphi}_5 - \left(\frac{1}{i}\right) \dot{\varphi}_0 \right] \left(\frac{1}{i}\right) = M_{EM} \quad (5.28.),$$

$$[J_5 + m_{uk}r_B^2]\ddot{\varphi}_5 + m_{uk}r_B(\varphi_5 r_B + x_u + \varphi_6 l_1) + c_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right)^2 \varphi_0 \right] + \frac{A_u E_u r_B}{2} (\varphi_5 r_B + x_u l_1) + k_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right) \varphi_0 \right] \quad (5.29.),$$

$$m_{uk}\ddot{x}_u + m_{uk}\ddot{\varphi}_5 r_B - m_{uk}g\varphi_5 r_B + A_u E_u x_u l_1 + k_u \dot{x}_u = F_V \varphi_6 \quad (5.30.),$$

$$2\ddot{\varphi}_6 l_1^2 + m_{uk}g l_1 \varphi_6 = F_V (\varphi_5 r_B + x_u) \quad (5.31.).$$

Sređivanjem gornjih jednačbi ((5.28.) – (5.31.)), dobiva se oblik prikladan za zapis u prostoru stanja, kao slijedeći sustav jednačbi:

$$\ddot{\varphi}_0 = \frac{1}{[J_0 + J_1] + J_2 \left(\frac{1}{i} \right)^2} \left[c_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right)^2 \varphi_0 \right] + k_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right) \varphi_0 \right] \left(\frac{1}{i} \right) - M_{EM} \right] \quad (5.32.),$$

$$\ddot{\varphi}_5 = - \frac{1}{[J_5 + m_{uk}r_B^2]} \left[m_{uk}r_B(r_B \varphi_5 + v + l_1 \varphi_6 + \ddot{v}) - c_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right)^2 \varphi_0 \right] - \frac{A_u E_u r_B}{2} (r_B \varphi_5 + l_1 x_u) - k_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right) \varphi_0 \right] \right] \quad (5.33.),$$

$$\ddot{x}_u = -r_B \ddot{\varphi}_5 + g r_B \varphi_5 - \frac{A_u E_u l_1}{m_{uk}} x_u - \frac{k_u}{m_{uk}} \dot{x}_u + \frac{F_V}{m_{uk}} \varphi_6 \quad (5.34.),$$

$$\ddot{\varphi}_6 = - \frac{1}{2l_1^2} [m_{uk}g l_1 \varphi_6 - F_V r_B \varphi_5 - x_u] \quad (5.35.).$$

Sređivanjem jednačbe (5.34.) dobiva se izraz:

$$\ddot{\varphi}_5 = \frac{F_V}{m_{uk}r_B} \varphi_6 + g \varphi_5 \quad (5.36.),$$

Nadalje pretpostavlja se da je koeficijent viskoznog prigušenja k_u čeličnog užeta vrlo mali, te se može zanemariti [136]. Stoga se i produljenje užeta x_u , kao i brzina produljenja užeta \dot{v} mogu zanemariti.

Konačni oblik diferencijalnih jednačbi gibanja sustava glasi:

$$\ddot{\varphi}_0 = \frac{1}{[J_0 + J_1] + J_2 \left(\frac{1}{i} \right)^2} \left[c_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right)^2 \varphi_0 \right] + k_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right) \varphi_0 \right] \left(\frac{1}{i} \right) - M_{EM} \right] \quad (5.37.),$$

$$\ddot{\varphi}_5 = - \frac{1}{[J_5 + m_{uk}r_B^2]} \left[m_{uk}r_B(r_B \varphi_5 + l_1 \varphi_6) - c_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right)^2 \varphi_0 \right] - \frac{A_u E_u r_B}{2} r_B \varphi_5 - k_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right) \varphi_0 \right] \right] \quad (5.38.),$$

$$\ddot{\varphi}_6 = - \frac{1}{2l_1^2} [m_{uk}g l_1 \varphi_6 - F_V r_B \varphi_5] \quad (5.39.).$$

Na osnovu danih jednažbi ((5.37.) – (5.39.)), kreira se zapis matematičkog modela sustava uređaja za dizanje tereta u prostoru stanja [72].

a) vektor derivacije stanja:

$$\dot{\mathbf{x}}(t) = \begin{bmatrix} \dot{\varphi}_0 \\ \dot{\varphi}_5 \\ \dot{\varphi}_6 \\ \dot{\omega}_0 \\ \dot{\omega}_5 \\ \dot{\omega}_6 \end{bmatrix} \quad (5.40.),$$

b) matrica dinamike sustava:

$$\mathbf{A} = \begin{bmatrix} 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ -\frac{k_{GV}}{i[(J_0+J_1)+J_2\cdot(\frac{1}{l})^2]} & \frac{k_{GV}}{(J_0+J_1)+J_2\cdot(\frac{1}{l})^2} & 0 & -(\frac{1}{l})^2 \frac{c_{GV}}{[(J_0+J_1)+J_2\cdot(\frac{1}{l})^2]} & \frac{c_{GV}}{(J_0+J_1)+J_2\cdot(\frac{1}{l})^2} & 0 \\ (\frac{1}{l})^2 \frac{c_{GV}}{J_5+m_{uk}r_B^2} & -\frac{m_{uk}r_B^2+c_{GV}+\frac{1}{2}A_{ul}E_{ul}r_B^2}{J_5+m_{uk}r_B^2} & -\frac{m_{uk}r_B l_1}{J_5+m_{uk}r_B^2} & -\frac{1}{i(J_5+m_{uk}r_B^2)} & \frac{k_{GV}}{J_5+m_{uk}r_B^2} & 0 \\ 0 & 0 & 0 & 0 & \frac{F_V r_B}{2l_1^2} & -\frac{m_{uk}g}{2l_1} \end{bmatrix} \quad (5.41.),$$

c) vektor stanja:

$$\mathbf{x}(t) = \begin{bmatrix} \varphi_0 \\ \varphi_5 \\ \varphi_6 \\ \omega_0 \\ \omega_5 \\ \omega_6 \end{bmatrix} \quad (5.42.),$$

d) matrica raspodjele upravljanja sustavom:

$$\mathbf{B} = \begin{bmatrix} -1 \\ \frac{1}{[(J_0+J_1)+J_2\cdot(\frac{1}{l})^2]} \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (5.43.),$$

e) vektor pobuda na sustav:

$$\mathbf{u}(t) = [M_{EM}] \quad (5.44.),$$

f) matrica mjerenja (senzora) sustava:

$$\mathbf{C} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (5.45.),$$

g) matrica izravnog prolaza pobude na izlaz sustava:

$$\mathbf{D} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (5.46.).$$

Na osnovu prikazanih varijabli i matrica, u jednađbama ((5.40.) – (5.46.)) kreira se matematički model zapisa sustava u prostoru stanja, tj. programski kod u računalnom programu *MATLAB* [137].

3. Simuliranje sustava korištenjem MPC metode

Na temelju kreiranog matematičkog modela ponašanja sustava u prostoru stanja (u računalnom programu *MATLAB* [137]), simulira se ponašanje sustava MPC metodom.

U MPC metodi kao i ispitivanju stabilnosti sustava, koriste se utjecajne varijable koje su prikazane u tablici 5.1. Kao što se vidi utjecajne varijable su: n_M [min^{-1}] – brzina vrtnje elektromotora (a), i [-] – ukupni prijenosni omjer u prijenosniku snage (b), m_T [t] – masa tereta (c), v_V [m/s] – brzina vjetrova (d) i težinski faktor ρ [-] (e).

Tablica 5.1. Prikaz raspona utjecajnih varijabli (u koracima iteracije 1 i 2)

a)	<table><tr><td>n_M [min⁻¹]</td></tr><tr><td>60 – 3000</td></tr></table>	n_M [min ⁻¹]	60 – 3000	b)	<table><tr><td>i [-]</td></tr><tr><td>10 – 200</td></tr></table>	i [-]	10 – 200
n_M [min ⁻¹]							
60 – 3000							
i [-]							
10 – 200							
c)	<table><tr><td>m_T [t]</td></tr><tr><td>1 – 10</td></tr></table>	m_T [t]	1 – 10	d)	<table><tr><td>v_V [m/s]</td></tr><tr><td>13.9 – 27.8</td></tr></table>	v_V [m/s]	13.9 – 27.8
m_T [t]							
1 – 10							
v_V [m/s]							
13.9 – 27.8							
e)	<table><tr><td>ρ [-]</td></tr><tr><td>0 – 1</td></tr></table>	ρ [-]	0 – 1				
ρ [-]							
0 – 1							

Utjecajne varijable su odabrane na temelju procjene konstruktora, koji smatra da one imaju najveći utjecaj na ponašanje promatranog sustava. Varijable se tokom analize ponašanja sustava u MPC metodi, međusobno variraju među sobom. Model MPC metode kreira se u računalnom programu *MATLAB Model Predictive Control Toolbox* [138] i to korištenjem potprograma *MPC Design Tool*.

Nakon što se odsimulira MPC metoda, dobiju se odzivi izlaznih varijabli, prikazani na slici 5.5. b. pod točkom 5.1.2.

4. Ispitivanje stabilnosti sustava

Na analogan način kao i u prethodnoj operaciji algoritma, za matematički model sustava (u prostoru stanja), simulira se ispitivanje stabilnosti izravnom metodom Ljapunova. Model je kreiran u računalnom programu *MATLAB* [137].

Pritom se koriste utjecajne varijable, koje su prikazane u tablici 5.1. Rezultat ispitivanja stabilnosti sustava prikazan je na slici 5.5. c.

5. Kreiranje neizrazitih pravila ponašanja i njihov grafički prikaz

Na osnovu podataka dobivenih MPC metodom, te ispitivanja stabilnosti sustava, uz podatke iz matematičkog modela sustava, kreira se Mamdani model neizrazite logike.

U tu svrhu koristi se sustav za odlučivanje u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139]. Semantika utjecajnih varijabli, prikazana je u tablici 5.2. Slika 5.4. prikazuje definirana neizrazita pravila ponašanja u koraku iteracije 1.

Rezultati lokalnog i globalnog zaključivanja prikazani su u dobivenim rezultatima na slici 5.6. Lokalno odlučivanje daje nam sheme odlučivanja, dok nam globalno zaključivanje daje trodimenzionalni (3D) prikaz odabranih dviju ulaznih varijabli i jedne izlazne varijable.

Izlazna varijabla je u ovom slučaju podatak je li sustav asimptotski stabilan ili nestabilan za prikazanu semantiku ulaznih varijabli. Koristi se Mamdani model odlučivanja neizrazitom logikom.

Prema definiranim neizrazitim pravilima na slici 5.4. može se primjetiti da se promatrani sustav uređaja za dizanje tereta ponaša asimptotski stabilno jedino u slučajevima raspona malih brzina vrtnja elektromotora n_M , te kod malih i srednjih ukupnih prijenosnih omjera i , i to u slučaju srednjih i velikih masa tereta m_T , te u slučaju srednjih i velikih brzina vjetrova v_V . U većini ostalih slučajeva promatrani sustav se ponaša nestabilno.

Dobiveni rezultati bit će još prokomentirani pod točkom 5.1.2.

Tablica 5.2. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koracima iteracije 1 i 2)

a)

n_M [min ⁻¹]	Raspon	Semantika
600 – 1000	0	Vrlo malo
1000 – 1500	0.25	Malo
1500 – 2000	0.5	Srednje
2000 – 2500	0.75	Veliko
2500 - 3000	1	Vrlo veliko

b)

i [-]	Raspon	Semantika
10 – 40	0	Vrlo malo
40 – 80	0.25	Malo
80 – 120	0.5	Srednje
120– 160	0.75	Veliko
160 – 200	1	Vrlo veliko

c)

m_T [t]	Raspon	Semantika
1 – 2	0	Vrlo malo
2 – 4	0.25	Malo
4 – 6	0.5	Srednje
6 – 8	0.75	Veliko
8 – 10	1	Vrlo veliko

d)

v_v [m/s]	Raspon	Semantika
13.9 – 16.7	0	Vrlo malo
16.7 – 19.4	0.25	Malo
19.4 – 22.2	0.5	Srednje
22.2 – 25	0.75	Veliko
25 – 27.8	1	Vrlo veliko

e)

ρ [-]	Raspon	Semantika
0 – 0.2	0	Vrlo malo
0.2 – 0.4	0.25	Malo
0.4 – 0.6	0.5	Srednje
0.6 – 0.8	0.75	Veliko
0.8 – 1	1	Vrlo veliko

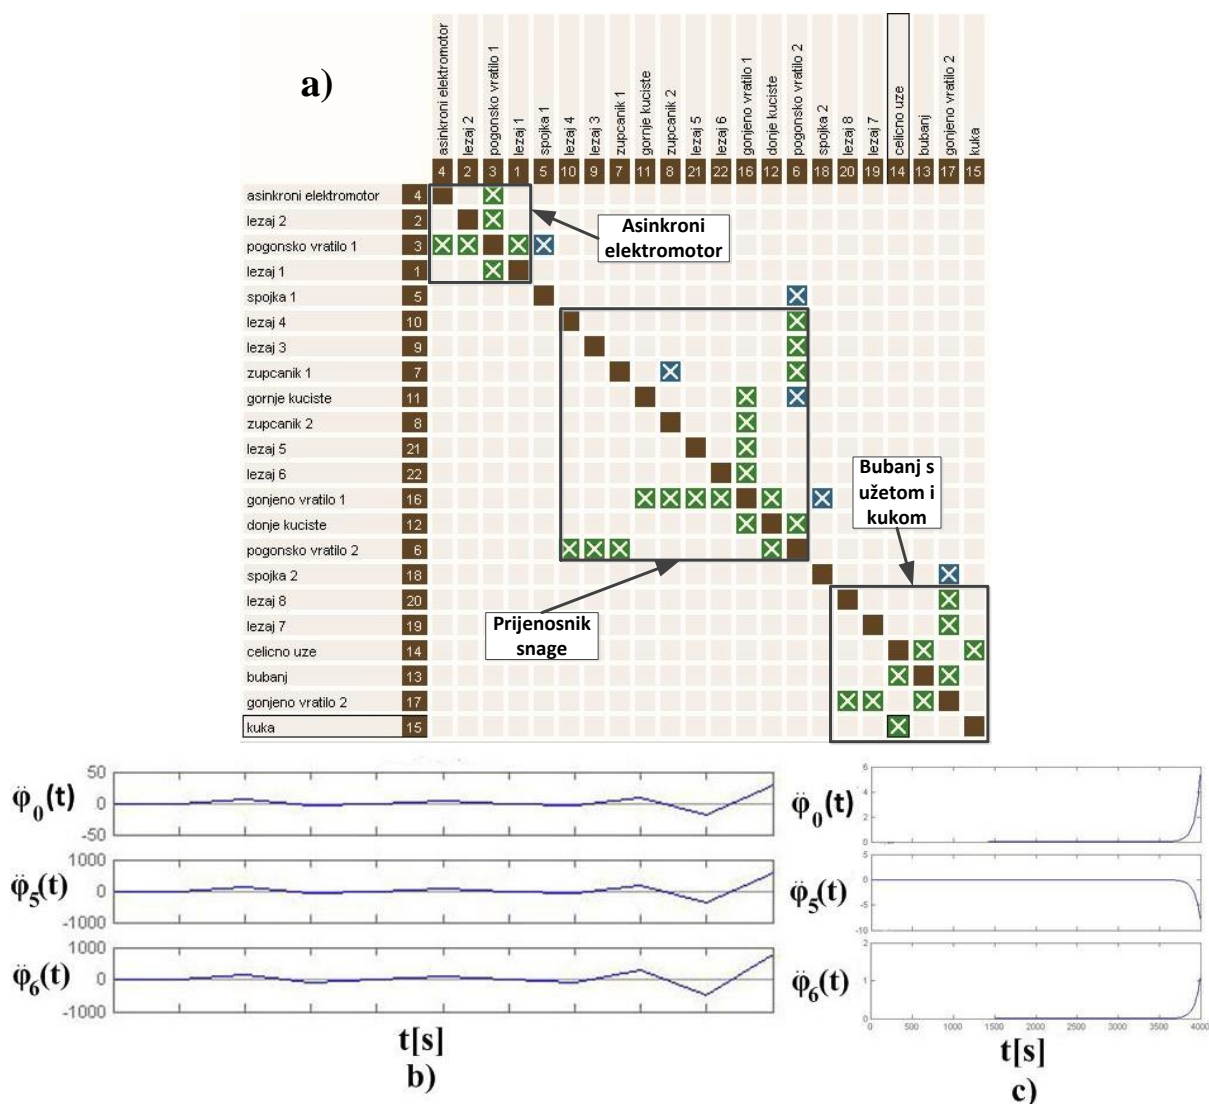
1. If (nM is vrlo_malo) and (i is vrlo_veliko) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
2. If (nM is vrlo_malo) and (i is vrlo_veliko) and (mT is vrlo_veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
3. If (nM is vrlo_malo) and (i is vrlo_veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
4. If (nM is malo) and (i is vrlo_veliko) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
5. If (nM is malo) and (i is veliko) and (mT is veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
6. If (nM is malo) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
7. If (nM is malo) and (i is srednje) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
8. If (nM is malo) and (i is srednje) and (mT is srednje) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
9. If (nM is malo) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
10. If (nM is srednje) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
11. If (nM is srednje) and (i is srednje) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
12. If (nM is veliko) and (i is srednje) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
13. If (nM is veliko) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
14. If (nM is veliko) and (i is veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
15. If (nM is veliko) and (i is veliko) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
16. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
17. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
18. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is malo) and (vV is malo) then (stabilnost_sustava is asimptotski_stabilno) (1)

Slika 5.4. Definirana neizrazita pravila ponašanja u koraku iteracije 1

6. Zapis neizrazitih pravila ponašanja

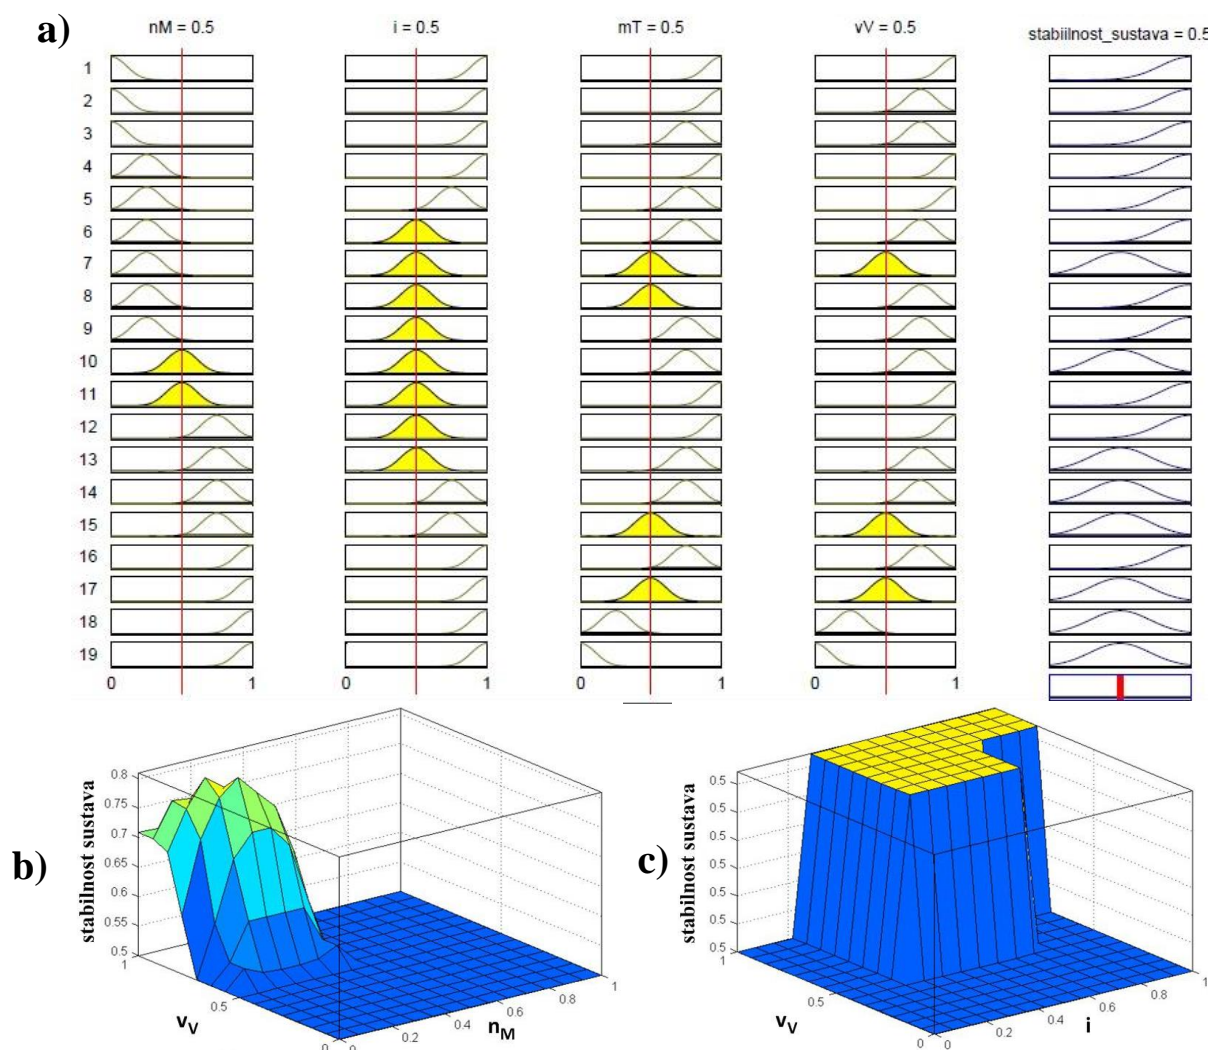
Neizrazita pravila ponašanja sustava zapisati će se u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139] u obliku *fis* datoteke.

5.1.2. Dobiveni rezultati nakon koraka iteracije 1



Slika 5.5. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) matrica komponenta DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.5. b daje nam grafički prikaz odziva izlaznih varijabli korištenjem MPC metode, dok nam slika 5.5. c prikazuje grafički odzive istih derivacija varijabli sustava na početne uvjete, korištenjem izravne metode Ljapunova. Na slici 5.5. b i c prikazani su odzivi izlaznih varijabli kad se promatrani sustav ponaša nestabilno.



Slika 5.6. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable n_M i v_V , c) rezultati globalnog zaključivanja za ulazne varijable i i v_V

Kao primjer ulaznih varijabli odabrane su u (slika 5.6. b) brzina vjetra v_V i broj okretaja elektromotora n_M , dok su u drugom slučaju (slika 5.6. c) to ulazne varijable brzina vjetra v_V i ukupni prijenosni omjer u prijenosniku snage i . Sa slike 5.6. b je vidljivo da se asimptotski stabilan sustav postiže u slučaju malih i srednjih brzina okretaja elektromotora za slučaj velikih brzina vjetra. Slika 5.6. c nam opet prikazuje da se asimptotski stabilan slučaj postiže u kombinaciji malih i srednjih ukupnih prijenosnih omjera kod srednjih i velikih brzina vjetra, odnosno velikih i vrlo velikih ukupnih prijenosnih omjera kod vrlo velikih brzina vjetra.

5.1.3. Tablični prikaz rezultata nakon koraka iteracije 1

Tablica 5.3. daje tablični prikaz rezultata na kraju koraka iteracije 1 za pojedine operacije algoritma. Prema neizrazitim pravilima ponašanja može se uočiti da se sustav ponaša nestabilno, te da najveći utjecaj na to imaju male i vrlo velike brzine vrtnje elektromotora, uz velike prijenosne omjere, mase tereta i brzine vjetra.

Tablica 5.3. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 1

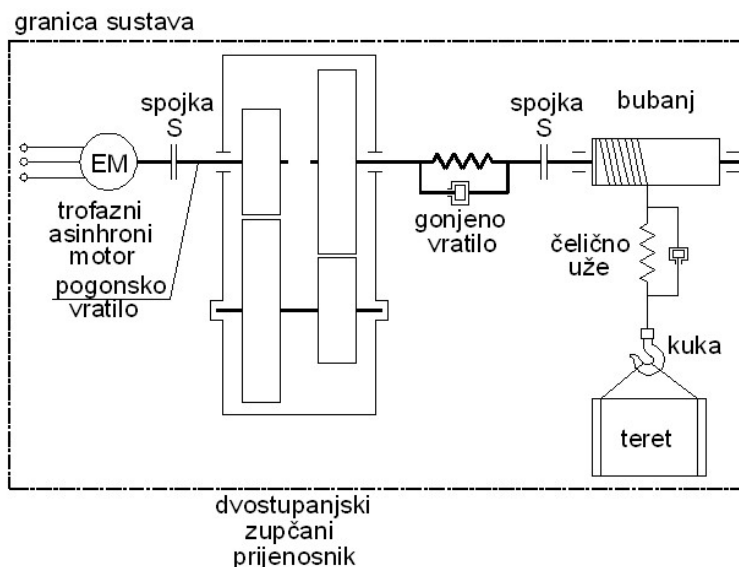
Arhitektura sustava	Podsustavi: trofazni asinkroni elektromotor, jednostupanjski prijenosnik snage sa pogonskim i gonjenim vratilom, te sa spojka na pogonskom i gonjenom vratilu i ležajevima, bubanj za dizanje s čeličnim užetom i kukom za prihvata tereta
Matematički model sustava	Sustav običnih linearnih diferencijalnih jednačbi, dobivenih nakon postupka linearizacije (prikazan u prostoru stanja)
MPC metoda	Moguće je postići kvalitetnu simulaciju ponašanja sustava, osim u nestabilnom području
Ispitivanje stabilnosti sustava	Sustav pokazuje nestabilno ponašanje u slučajevima malih i vrlo velikih brzina vrtnje elektromotora, uz velike prijenosne omjere, mase tereta i brzine vjetra

5.1.4. Korak iteracije 2

U koraku iteracije 2 dodaje se još jedan stupanj u prijenosniku snage, zbog mogućnosti povećanja prijenosnog omjera, a samim time i dobivanje stabilnijeg sustava kod većih brzina vjetra (prikazano na slici 5.7.).

1. Opisivanje arhitekture sustava

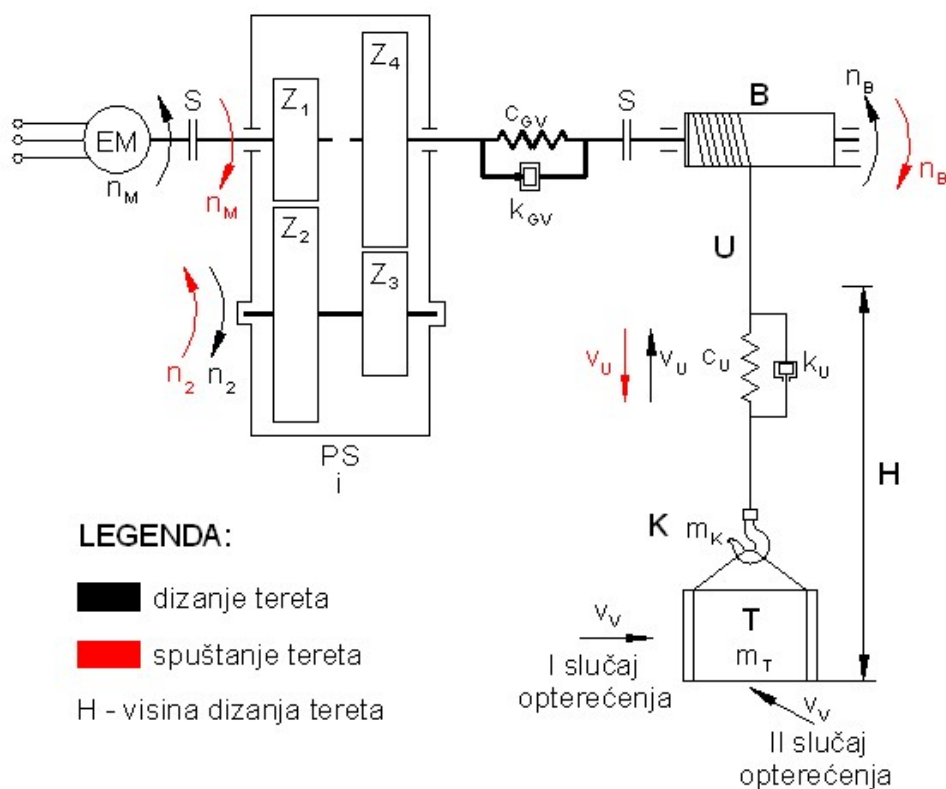
Kao i u prethodnom koraku, matricom komponenata DSM je opisana arhitektura sustava sa mogućim podsustavima. Dobiveni rezultati prikazani su na slici 5.10. a. Za dobivanje rezultata korišten je računalni program *LOOME* [128].



Slika 5.7. Arhitektura sustava uređaja za dizanje (korak iteracije 2)

2. Kreiranje matematičkog modela ponašanja sustava

U ovom koraku iteracije za kreiranje matematičkog modela ponašanja sustava, koriste se iste diferencijalne jednačbe ((5.38.) – (5.39.)), jedino se mijenja jednačba (5.37.), kako je to u nastavku prikazano.



Slika 5.8. Shematski prikaz sa oznakama pojedinih podsustava (korak iteracije 2)

Zbog dvostupanjskog prijenosnika snage ([132] – [134]), jednačba (5.37.) se proširuje na slijedeći oblik:

$$\left[(J_0 + J_1) + (J_2 + J_3) \cdot \left(\frac{1}{i_1} \right)^2 + J_4 \cdot \left(\frac{1}{i} \right)^2 \right] \cdot \ddot{\varphi}_0 - c_{GV} \left[\dot{\varphi}_5 - \left(\frac{1}{i} \right)^2 \dot{\varphi}_0 \right] - k_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right) \varphi_0 \right] \left(\frac{1}{i} \right) = M_{EM} \quad (5.47.),$$

gdje su još:

J_3 [kgm²] – dinamički moment inercije zupčanika 3, računa se prema formuli:

$J_3 = \frac{1}{2} m_3 r_3^2$, gdje se vrijednosti za masu zupčanika 3, računaju približno prema formuli:

$$m_3 = \rho \cdot V_3 = \rho \cdot \frac{D_3^2}{4} \cdot h_3 \text{ [kg]}$$

J_4 [kgm²] – dinamički moment inercije zupčanika 4, računa se prema formuli:

$J_4 = \frac{1}{2} m_4 r_4^2$, gdje se vrijednosti za masu zupčanika 4, također računaju približno prema formuli:

$$m_4 = \rho \cdot V_4 = \rho \cdot \frac{D_4^2}{4} \cdot h_4 \text{ [kg]}$$

i_1 [-] –prijenosni omjer prvog stupnja u prijenosniku snage,

Jednačbe iz prethodnog koraka iteracije ((5.38.) - (5.39.)), te jednačba (5.47.) se prikazuju u obliku prikladnom za zapis u prostoru stanja.

Konačni oblik diferencijalnih jednačbi glasi:

$$\ddot{\varphi}_0 = \frac{1}{\left[(J_0 + J_1) + (J_2 + J_3) \cdot \left(\frac{1}{i_1} \right)^2 + J_4 \cdot \left(\frac{1}{i} \right)^2 \right]} \left[c_{GV} \left[\dot{\varphi}_5 - \left(\frac{1}{i} \right)^2 \dot{\varphi}_0 \right] + k_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right) \varphi_0 \right] \left(\frac{1}{i} \right) - M_{EM} \right] \quad (5.48.),$$

$$\ddot{\varphi}_5 = - \frac{1}{[J_5 + m_{uk} r_B^2]} [m_{uk} r_B (r_B \dot{\varphi}_5 + l_1 \dot{\varphi}_6) - c_{GV} \left[\dot{\varphi}_5 - \left(\frac{1}{i} \right)^2 \dot{\varphi}_0 \right] - \frac{A_u E_u r_B}{2} r_B \dot{\varphi}_5 - k_{GV} \left[\varphi_5 - \left(\frac{1}{i} \right) \varphi_0 \right]] \quad (5.49.),$$

$$\ddot{\varphi}_6 = - \frac{1}{2l_1^2} [m_{uk} g l_1 \varphi_6 - F_V r_B \varphi_5] \quad (5.50.).$$

Na osnovu danih jednačbi ((5.48.) – (5.50.)), kreira se zapis matematičkog modela ponašanja sustava uređaja za dizanje tereta u prostoru stanja [72].

a) vektor derivacije stanja:

$$\dot{\mathbf{x}}(t) = \begin{bmatrix} \dot{\varphi}_0 \\ \dot{\varphi}_5 \\ \dot{\varphi}_6 \\ \dot{\omega}_0 \\ \dot{\omega}_5 \\ \dot{\omega}_6 \end{bmatrix} \quad (5.51.),$$

b) matrica dinamike sustava:

$\mathbf{A} =$

$$\begin{bmatrix} 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \\ -\frac{k_{GV}}{i[(J_0+J_1)+(J_2+J_3)\cdot(\frac{1}{i_1})^2+J_4\cdot(\frac{1}{i})^2]} & \frac{k_{GV}}{(J_0+J_1)+(J_2+J_3)\cdot(\frac{1}{i_1})^2+J_4\cdot(\frac{1}{i})^2} & 0 & -(\frac{1}{i})^2 \frac{c_{GV}}{[(J_0+J_1)+(J_2+J_3)\cdot(\frac{1}{i_1})^2+J_4\cdot(\frac{1}{i})^2]} & \frac{c_{GV}}{(J_0+J_1)+(J_2+J_3)\cdot(\frac{1}{i_1})^2+J_4\cdot(\frac{1}{i})^2} & 0 \\ (\frac{1}{i})^2 \frac{c_{GV}}{J_5+m_{uk}r_B^2} & -\frac{m_{uk}r_B^2+c_{GV}+\frac{1}{2}A_u E_u r_B^2}{J_5+m_{uk}r_B^2} & -\frac{m_{uk}r_B l_1}{J_5+m_{uk}r_B^2} & -\frac{1}{i(J_5+m_{uk}r_B^2)} & \frac{k_{GV}}{J_5+m_{uk}r_B^2} & 0 \\ 0 & 0 & 0 & 0 & \frac{F_V r_B}{2l_1^2} & -\frac{m_{uk}g l_1}{2l_1^2} \end{bmatrix} \quad (5.52.),$$

c) vektor stanja:

$$\mathbf{x}(t) = \begin{bmatrix} \varphi_0 \\ \varphi_5 \\ \varphi_6 \\ \omega_0 \\ \omega_5 \\ \omega_6 \end{bmatrix} \quad (5.53.),$$

d) matrica raspodjele upravljanja sustavom:

$$\mathbf{B} = \begin{bmatrix} -1 \\ \left[(J_0+J_1)+(J_2+J_3)\cdot(\frac{1}{i_1})^2+J_4\cdot(\frac{1}{i})^2 \right] \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (5.54.),$$

e) vektor pobuda na sustav:

$$\mathbf{u}(t) = [M_{EM}] \quad (5.55.),$$

f) matrica mjerenja (senzora) sustava:

$$\mathbf{C} = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (5.56.),$$

g) matrica izravnog prolaza pobude na izlaz sustava:

$$\mathbf{D} = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{bmatrix} \quad (5.57.).$$

Na osnovu prikazanih varijabli i matrica ((5.51.) – (5.57.)), kreira se matematički model ponašanja sustava zapisan u prostoru stanja, tj. kreira se programski kod u računalnom programu *MATLAB* [137].

3. Simuliranje sustava korištenjem MPC metode

Na temelju kreiranog matematičkog modela u prostoru stanja (u računalnom programu *MATLAB*), simulira se ponašanje sustava MPC metodom. Model MPC metode kreira se pomoću računalnog programa *MATLAB Model Predictive Control Toolbox* [138] i to korištenjem potprograma *MPC Design Tool*.

U MPC metodi kao i ispitivanju stabilnosti sustava, koriste se utjecajne varijable (koje su prikazane u tablici 5.1.), kao i u prethodnom koraku varijable se tokom analize ponašanja sustava u MPC metodi, međusobno variraju među sobom.

Nakon što se odsimulira MPC metoda, dobiju se odzivi izlaznih varijabli, prikazani na slici 5.10. b. pod točkom 5.1.5.

4. Ispitivanje stabilnosti sustava

Na analogan način kao i u prethodnom koraku iteracije, za matematički model sustava (u prostoru stanja), simulira se ispitivanje stabilnosti izravnom metodom Ljapunova. Model je kreiran u računalnom programu *MATLAB* [137].

Pritom se koriste iste utjecajne varijable (kao i u prethodnom koraku iteracije 1, koje su prikazane u tablici 5.1. Rezultat ispitivanja stabilnosti sustava prikazan je na slici 5.10. c.

5. Kreiranje neizrazitih pravila ponašanja i njihov grafički prikaz

Na osnovu podataka dobivenih MPC metodom, te ispitivanja stabilnosti sustava, uz podatke iz matematičkog modela sustava, kreira se Mamdani model neizrazite logike. U tu svrhu koristi se sustav za odlučivanje u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139]. Semantika utjecajnih varijabli, prikazana je u tablici 5.2. Slika 5.9. prikazuje definirana neizrazita pravila ponašanja u koraku iteracije 2.

Rezultati lokalnog i globalnog zaključivanja prikazani su u dobivenim rezultatima na slici 5.11. Dobiveni rezultati bit će još prokomentirani pod točkom 5.1.5.

```

1. If (nM is vrlo_veliko) and (i is veliko) and (mT is veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
2. If (nM is vrlo_malo) and (i is vrlo_veliko) and (mT is vrlo_veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
3. If (nM is vrlo_malo) and (i is vrlo_veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
4. If (nM is malo) and (i is vrlo_veliko) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
5. If (nM is malo) and (i is veliko) and (mT is veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
6. If (nM is malo) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
7. If (nM is malo) and (i is srednje) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
8. If (nM is malo) and (i is srednje) and (mT is srednje) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
9. If (nM is malo) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
10. If (nM is srednje) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
11. If (nM is srednje) and (i is srednje) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
12. If (nM is veliko) and (i is srednje) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
13. If (nM is veliko) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
14. If (nM is veliko) and (i is veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
15. If (nM is veliko) and (i is veliko) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
16. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
17. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
18. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is malo) and (vV is malo) then (stabilnost_sustava is asimptotski_stabilno) (1)

```

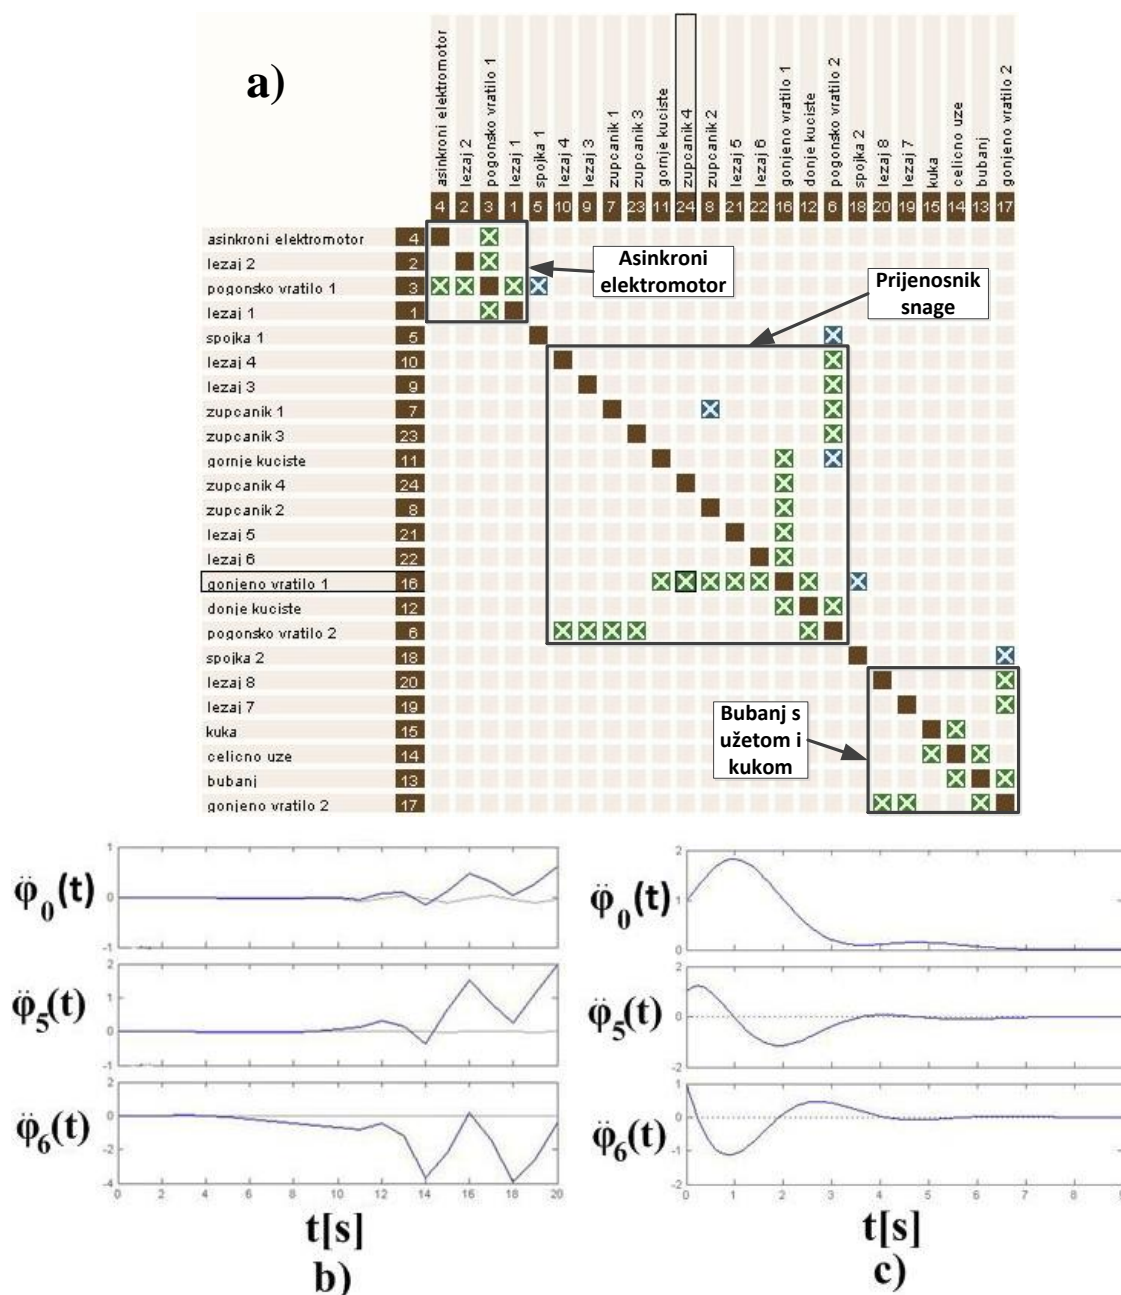
Slika 5.9. Definirana neizrazita pravila ponašanja u koraku iteracije 2

Prema definiranim neizrazitim pravilima ponašanja (na slici 5.9.) u odnosu na korak iteracije 1 može se primjetiti slijedeće. Promjenom podsustava prijenosnika snage sustav uređaja za dizanje tereta ponaša se asimptotski stabilno i u slučajevima raspona malih i srednjih brzina vrtnja elektromotora n_M , te kod srednjih ukupnih prijenosnih omjera i , i to u slučaju velikih masa tereta m_T , te u slučaju velikih brzina vjetra v_V .

6. Zapis neizrazitih pravila ponašanja


Neizrazita pravila ponašanja sustava zapisati će se u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139] u obliku *fis* datoteke.

5.1.5. Dobiveni rezultati nakon koraka iteracije 2



Slika 5.10. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) matrica komponenta DSM, b) MPC metoda - odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Na slici 5.10 b i c prikazani su odzivi izlaznih varijabli (kod MPC metode, odnosno kod izravne metode Ljapunova) varijabli sustava kad se promatrani sustav ponaša asimptotski stabilno.



Slika 5.11. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable n_M i v_V , c) rezultati globalnog zaključivanja za ulazne varijable i i v_V

Kao i u koraku iteracije 1, odabrane su iste ulazne varijable (slika 5.11. b i c). Sa slike 5.11 b je vidljivo da se asimptotski stabilan sustav postiže u slučaju malih i srednjih brzina okretaja elektromotora za slučaj velikih i vrlo velikih brzina vjetra. Slika 5.11. c nam kao i u koraku iteracije 1 prikazuje da se asimptotski stabilan slučaj postiže u kombinaciji malih i srednjih ukupnih prijenosnih omjera, kod srednjih i velikih brzina vjetra, odnosno velikih i vrlo velikih ukupnih prijenosnih omjera kod vrlo velikih brzina vjetra.

5.1.6. Tablični prikaz rezultata nakon koraka iteracije 2

Tablica 5.12. daje tablični prikaz rezultata na kraju koraka iteracije 2 za pojedine operacije algoritma. Prema neizrazitim pravilima ponašanja može se uočiti da se sustav ponaša nestabilno u slučajevima malih i vrlo velikih brzina vrtnje elektromotora, uz velike prijenosne omjere, mase tereta i brzine vjetra.

Tablica 5.4. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 2

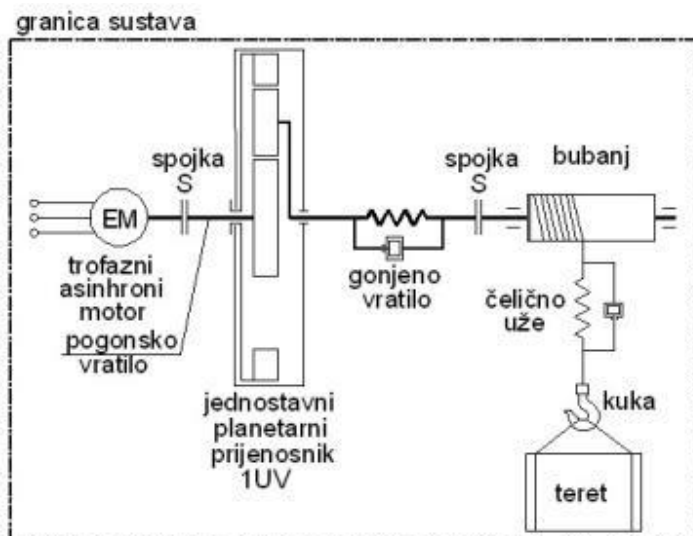
Arhitektura sustava	Podsustavi: trofazni asinkroni elektromotor, dvostupanjski prijenosnik snage sa pogonskim i gonjenim vratilom, spojke na pogonskom i gonjenom vratilu i ležajevi, bubanj za dizanje s čeličnim užetom i kukom za prihvat tereta
Matematički model sustava	Sustav običnih linearnih diferencijalnih jednažbi, dobivenih nakon postupka linearizacije (prikazan u prostoru stanja)
MPC metoda	Moguće je postići kvalitetnu simulaciju ponašanja sustava, osim u nestabilnom području
Ispitivanje stabilnosti sustava	Sustav pokazuje nestabilno ponašanje u slučajevima malih i vrlo velikih brzina vrtnji elektromotora, uz velike prijenosne omjere, mase tereta i brzine vjetra

5.1.7. Korak iteracije 3

U koraku iteracije 3 kao prijenosnik snage, uzima se jednostavni planetarni prijenosnik 1UV ([133], [119]), zbog mogućnosti rada uređaja s većim prijenosnim omjerima, te dobivanja većih brzina dizanja/spuštanja tereta (prikazano na slici 5.12.).

1. Opisivanje arhitekture sustava


Korištenjem matrice komponenata DSM opisali smo arhitekturu sustava, koja je matrično prikazana na slici 5.15. a sa mogućim podsustavima. U tu svrhu korišten je računalni program *LOOME0* [128].



Slika 5.12. Arhitektura sustava uređaja za dizanje tereta (korak iteracije 3)

2. Kreiranje matematičkog modela ponašanja sustava

Za matematički model ponašanja sustava u koraku iteracije 3 (prema slici 5.13.), vrijede iste diferencijalne jednačbe, kao i u koraku iteracije 1 ((5.38.) – (5.39.)), uz jednačbu (5.47.). Stoga se one ovdje neće ponovo izvoditi. Na osnovu tih jednačbi kreira se zapis matematičkog modela sustava uređaja za dizanje tereta u prostoru stanja. Jednačbe koje opisuju model prostora stanja su iste kao i u koraku iteracije 1 ((5.40.) – (5.46.)).



Slika 5.13. Shematski prikaz sa oznakama pojedinih podsustava (korak iteracije 3)

3. Simuliranje sustava korištenjem MPC metode

Na temelju kreiranog matematičkog modela u prostoru stanja (u računalnom programu *MATLAB* [137]), simulira se ponašanje sustava MPC metodom. Model MPC metode se kreira u računalnom programu *MATLAB Model Predictive Control Toolbox* [138] i to korištenjem potprograma *MPC Design Tool*.

U MPC metodi, koriste se utjecajne varijable koje su prikazane u tablici 5.5. U odnosu na korak iteracije 1 i 2 promijenio se raspon varijabli prijenosnog omjera. Promatra se veći raspon prijenosnog omjera zbog odabranog planetarnog prijenosnika 1UV, kojim možemo postići veće prijenosne omjere ([132], [133]).

Utjecajne varijable su prema tablici 5.5.: n_M [min^{-1}] – brzina vrtnje elektromotora (a), i [-] – ukupni prijenosni omjer u prijenosniku snage (b), m_T [t] – masa tereta (c), v_V [m/s] – brzina vjetra (d) i težinski faktor ρ [-] (e). Utjecajne varijable su odabrane na temelju procjene konstruktora, koji smatra da one imaju najveći utjecaj na ponašanje promatranog sustava.

Ponavlja se isti postupak kao i u prethodnim koracima iteracije. Varijable se tokom analize ponašanja sustava u MPC metodi, međusobno variraju među sobom. Nakon što se odsimulira MPC metoda, dobiju se odzivi izlaznih varijabli, prikazani na slici 5.15. b. pod točkom 5.1.5.

Tablica 5.5. Prikaz raspona utjecajnih varijabli (u koraku iteracije 3)

a)	<table><tr><td>n_M [min⁻¹]</td></tr><tr><td>60 – 3000</td></tr></table>	n_M [min ⁻¹]	60 – 3000	b)	<table><tr><td>i [-]</td></tr><tr><td>200 – 400</td></tr></table>	i [-]	200 – 400
n_M [min ⁻¹]							
60 – 3000							
i [-]							
200 – 400							
c)	<table><tr><td>m_T [t]</td></tr><tr><td>1 – 10</td></tr></table>	m_T [t]	1 – 10	d)	<table><tr><td>v_V [m/s]</td></tr><tr><td>13.9 – 27.8</td></tr></table>	v_V [m/s]	13.9 – 27.8
m_T [t]							
1 – 10							
v_V [m/s]							
13.9 – 27.8							
e)	<table><tr><td>ρ [-]</td></tr><tr><td>0 – 1</td></tr></table>	ρ [-]	0 – 1				
ρ [-]							
0 – 1							

4. Ispitivanje stabilnosti sustava

Na analogan način kao i u prethodnom koraku iteracije, za matematički model ponašanja sustava (u prostoru stanja), simulira se ispitivanje stabilnosti izravnom metodom Ljapunova. Računalni model je kreiran u računalnom programu *MATLAB* [137].

Pritom se koriste iste utjecajne varijable, koje su prikazane u tablici 5.5. Rezultat ispitivanja stabilnosti sustava prikazan je na slici 5.15. c.

5. Kreiranje neizrazitih pravila ponašanja i njihov grafički prikaz

Na osnovu podataka dobivenih MPC metodom, te ispitivanja stabilnosti sustava, uz podatke iz matematičkog modela sustava, kreira se Mamdani model neizrazite logike.

U tu svrhu koristi se sustav za odlučivanje u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139]. Semantika utjecajnih varijabli, prikazana je u tablici 5.6. Slika 5.14. prikazuje definirana neizrazita pravila ponašanja u koraku iteracije 3.

Rezultati lokalnog i globalnog zaključivanja prikazani su u dobivenim rezultatima na slici 5.16. Dobiveni rezultati bit će još prokomentirani pod točkom 5.1.8.

6. Zapis neizrazitih pravila ponašanja

Neizrazita pravila ponašanja sustava zapisati će se u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139] u obliku *fis* datoteke.

Tablica 5.6. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koraku iteracije 3)

a)	$n_M [\text{min}^{-1}]$	Raspon	Semantika
	600 – 1000	0	Vrlo malo
	1000 – 1500	0.25	Malo
	1500 – 2000	0.5	Srednje
	2000 – 2500	0.75	Veliko
	2500 – 3000	1	Vrlo veliko

b)	$i [-]$	Raspon	Semantika
	200 – 240	0	Vrlo malo
	240 – 280	0.25	Malo
	300 – 340	0.5	Srednje
	340 – 380	0.75	Veliko
	380 – 400	1	Vrlo veliko

c)	$m_T [\text{t}]$	Raspon	Semantika
	1 – 2	0	Vrlo malo
	2 – 4	0.25	Malo
	4 – 6	0.5	Srednje
	6 – 8	0.75	Veliko
	8 – 10	1	Vrlo veliko

d)	$v_T [\text{m/s}]$	Raspon	Semantika
	13.9 – 16.7	0	Vrlo malo
	16.7 – 19.4	0.25	Malo
	19.4 – 22.2	0.5	Srednje
	22.2 – 25	0.75	Veliko
	25 – 27.8	1	Vrlo veliko


e)	$\rho [-]$	Raspon	Semantika
	0 – 0.2	0	Vrlo malo
	0.2 – 0.4	0.25	Malo
	0.4 – 0.6	0.5	Srednje
	0.6 – 0.8	0.75	Veliko
	0.8 – 1	1	Vrlo veliko

1. If (nM is vrlo_veliko) and (i is veliko) and (mT is veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
2. If (nM is vrlo_malo) and (i is vrlo_veliko) and (mT is vrlo_veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
3. If (nM is vrlo_malo) and (i is vrlo_veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
4. If (nM is malo) and (i is vrlo_veliko) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
5. If (nM is malo) and (i is veliko) and (mT is veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
6. If (nM is malo) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
7. If (nM is malo) and (i is srednje) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
8. If (nM is malo) and (i is srednje) and (mT is srednje) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
9. If (nM is malo) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
10. If (nM is srednje) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
11. If (nM is srednje) and (i is srednje) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
12. If (nM is veliko) and (i is srednje) and (mT is vrlo_veliko) and (vV is vrlo_veliko) then (stabilnost_sustava is nestabilno) (1)
13. If (nM is veliko) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
14. If (nM is veliko) and (i is veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
15. If (nM is veliko) and (i is veliko) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
16. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
17. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
18. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is malo) and (vV is malo) then (stabilnost_sustava is asimptotski_stabilno) (1)

Slika 5.14. Definirana neizrazita pravila ponašanja u koraku iteracije 3

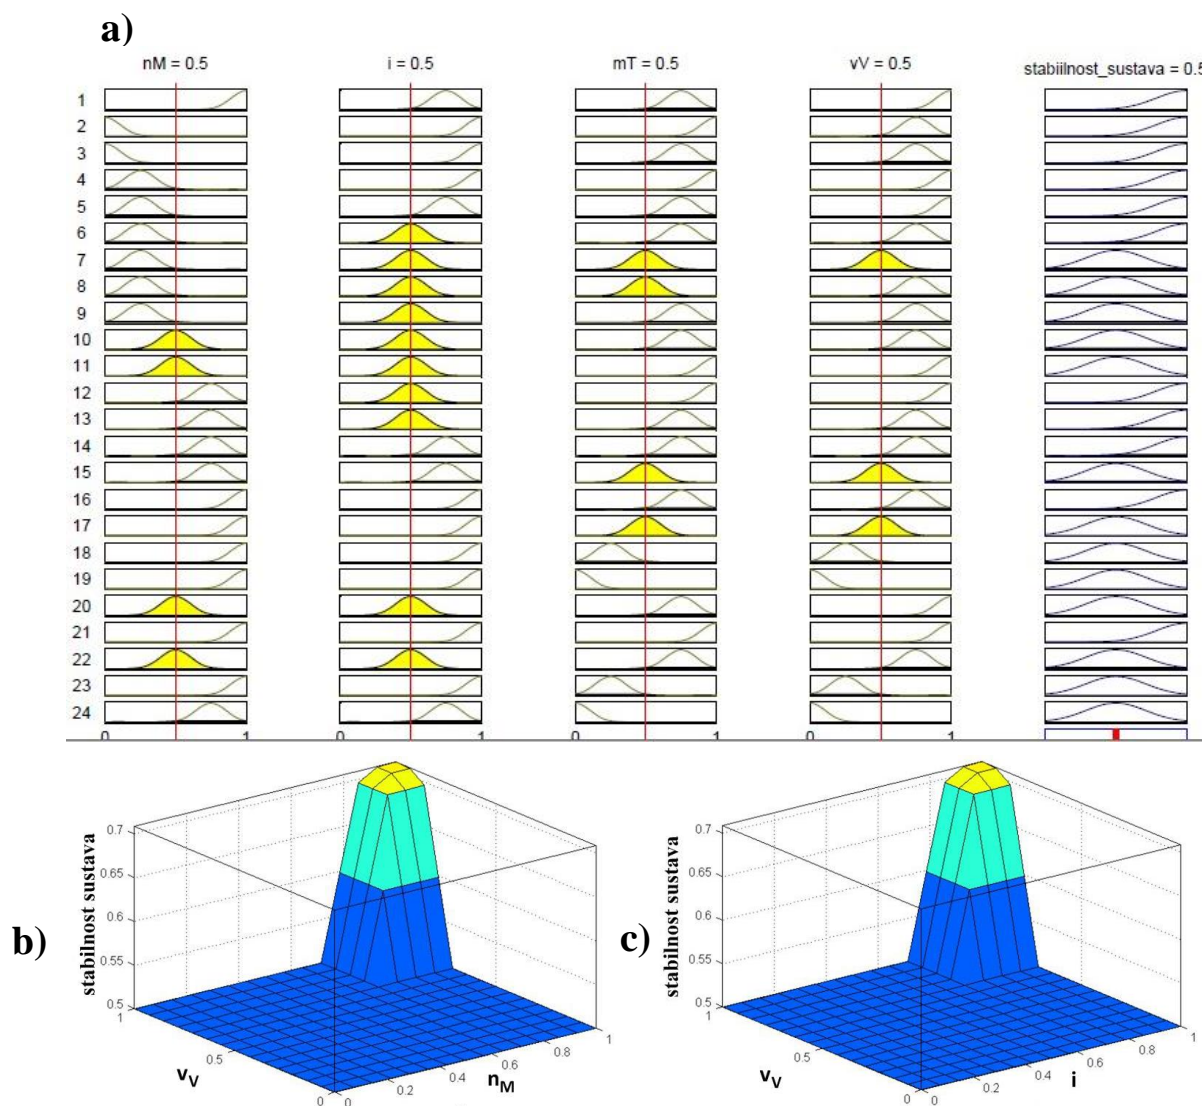
Prema definiranim neizrazitim pravilima ponašanja (na slici 5.14.) u odnosu na korak iteracije 2 može se primjetiti slijedeće. Promjenom podsustava prijenosnika snage sustav uređaja za dizanje tereta ponaša se nestabilno u slučajevima raspona velikih i vrlo velikih brzina vrtnja elektromotora n_M , te kod velikih ukupnih prijenosnih omjera i , i to u slučaju velikih masa tereta m_T , te u slučaju velikih i velikih brzina vjetra v_V . No ono što smo postigli dobili smo mogućnost rada sa većim prijenosnim omjerima uz mogućnost većih brzina dizanja, odnosno spuštanja tereta.

5.1.8. Dobiveni rezultati nakon koraka iteracije 3



Slika 5.15. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Na slici 5.15. b i c prikazani su odzivi izlaznih varijabli (kod MPC metode, odnosno kod izravne metode Ljapunova), kad se promatrani sustav ponaša asimptotski stabilno.



Slika 5.16. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable n_M i v_V , c) rezultati globalnog zaključivanja za ulazne varijable i i v_V

Kao i u prethodna dva koraka iteracije (1 i 2), odabrane su iste ulazne varijable (slika 5.16. b i c). Sa slike 5.16. b je vidljivo da se asimptotski stabilan sustav postiže u slučaju vrlo velikih brzina okretaja elektromotora za slučaj vrlo velikih brzina vjetra. Slika 5.16. c nam prikazuje da su potrebni vrlo veliki prijenosni omeri da bi se postigao asimptotski stabilan rad sustava, kod vrlo velikih brzina vjetra.

5.1.9. Tablični prikaz rezultata nakon koraka iteracije 3

Tablica 5.7. daje tablični prikaz rezultata na kraju koraka iteracije 3 za pojedine operacije algoritma. Prema neizrazitim pravilima ponašanja može se uočiti da se sustav ponaša nestabilno u slučajevima malih i vrlo velikih brzina vrtnje elektromotora, uz velike prijenosne omjere, mase tereta i brzine vjetra.

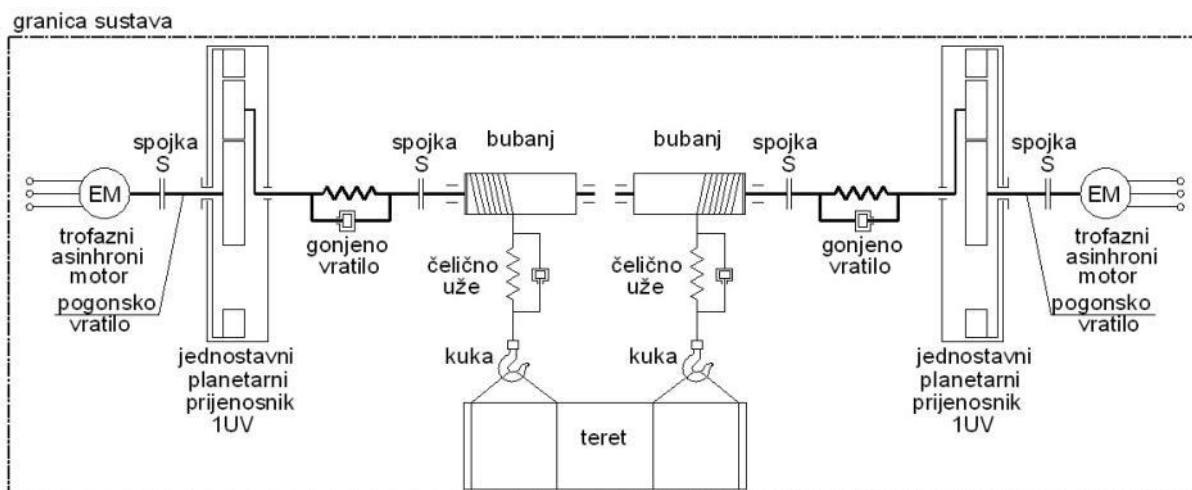
Promjenom prijenosnika snage u jednostavni planetarni prijenosnik tipa 1UV, postigli smo da smo dobili mogućnost rada pri većim prijenosnim omjerima u rasponu 200 – 400.

Tablica 5.7. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 3

Arhitektura sustava	Podsustavi: trofazni asinkroni elektromotor, jednostavni planetarni prijenosnik sa pogonskim i gonjenim vratilom, spojke na pogonskom i gonjenom vratilu i ležajevi, bubanj za dizanje s čeličnim užetom i kukom za prihvat tereta
Matematički model sustava	Sustav običnih linearnih diferencijalnih jednadžbi, dobivenih nakon postupka linearizacije (prikazan u prostoru stanja)
MPC metoda	Moguće je postići kvalitetnu simulaciju ponašanja sustava, osim u nestabilnom području
Ispitivanje stabilnosti sustava	Sustav pokazuje nestabilno ponašanje u slučajevima malih i vrlo velikih brzina vrtnji elektromotora, uz velike prijenosne omjere, mase tereta i brzine vjetra

5.1.10. Korak iteracije 4


U posljednjem koraku iteracije 4, promijenjena su pravila ponašanja uređaja za dizanje tereta. Dodan je još jedan sustav sa potpuno istim podsustavima, kao što je onaj u koraku 3 iteracije. Time se želi ostvariti mogućnost istovremenog dizanja/spuštanja većih tereta ([125], [126]) (prikazano na slici 5.17.). Oba podsustava rade ujednačeno, tj. s istim brzinama elektromotora, te s istim brzinama dizanja i spuštanja tereta.



Slika 5.17. Arhitektura sustava uređaja za dizanje nakon dodavanja novih pravila ponašanja (korak iteracije 4)

1. Opisivanje arhitekture sustava

Prvi korak je opisivanje arhitekture sustava sa mogućim podsustavima. U tu svrhu koristi se matrica komponenata DSM. Dobiveni rezultati prikazani su na slici 5.21. a. Kao i u prethodnim koracima iteracije i ovdje je korišten računalni program *LOOME0* [128].



Slika 5.18. Shematski prikaz sa oznakama pojedinih podsustava (korak iteracije 4)


2. Kreiranje matematičkog modela ponašanja sustava

Na osnovu dobivene arhitekture sustava i matričnog prikaza sustava sa podsustavima napravljen je shematski prikaz sa oznakama pojedinih podsustava (prikazano na slici 5.18.). Na osnovu njega kreira se matematički model ponašanja sustava.

Različitost ovog matematičkog modela ponašanja u odnosu na prethodni, je da se kod uzimanja mase tereta (u podsustavu 3 – prikazano na slici 5.19.), uzima samo polovica njene vrijednosti. Pretpostavlja se da polovicu mase tereta zahvaća jedna, odnosno druga kuka. Pritom se modificira jednačba (5.6.):

$$m_{uk} = m_K + \frac{m_T}{2} \quad (5.57.)$$

Za matematički model ponašanja sustava u koraku iteracije 4 (prema slici 5.18.), vrijede iste jednačbe, kao i u prethodnom koraku iteracije 3 ((5.38.) – (5.39.), (5.47.)). Na osnovu njih kreira se zapis matematičkog modela sustava uređaja za dizanje tereta u prostoru stanja. Jednačbe koje opisuju model prostora stanja su iste kao i u prethodnom koraku iteracije ((5.40.) – (5.46.)).



Slika 5.19. Shematski prikaz podsustava 3 sa oznakama (korak iteracije 4)

Tablica 5.8. Prikaz raspona utjecajnih varijabli (u koraku iteracije 4)

a)	$\frac{n_M [\text{min}^{-1}]}{60 - 3000}$	b)	$\frac{i [-]}{200 - 400}$
c)	$\frac{m_T [\text{t}]}{10 - 20}$	d)	$\frac{v_T [\text{m/s}]}{13.9 - 27.8}$
e)	$\frac{\rho [-]}{0 - 1}$		

3. Simuliranje sustava korištenjem MPC metode

Na temelju kreiranog matematičkog modela u prostoru stanja (u računalnom programu *MATLAB* [137]), simulira se ponašanje sustava MPC metodom.

U MPC metodi, koriste se utjecajne varijable koje su prikazane u tablici 5.8. U odnosu na prethodni korak iteracije, promijenio se raspon varijabli mase tereta. Sad se promatra veći raspon masa tereta zbog dvaju istih sustava koji rade istovremeno.

Utjecajne varijable su prema tablici 5.8.: $n_M [\text{min}^{-1}]$ – brzina vrtnje elektromotora (a), $i [-]$ – ukupni prijenosni omjer u prijenosniku snage (b), $m_T [\text{t}]$ – masa tereta (c), $v_T [\text{m/s}]$ – brzina vjetra (d) i težinski faktor $\rho [-]$ (e). Utjecajne varijable su odabrane na temelju procjene konstruktora, koji smatra da one imaju najveći utjecaj na ponašanje promatranog sustava.

Model MPC metode kreiran je u računalnom programu *MATLAB Model Predictive Control Toolbox* [138] i to korištenjem potprograma *MPC Design Tool*.

Ponavlja se isti postupak kao i u prethodnim koracima iteracije. Varijable se tokom analize ponašanja sustava u MPC metodi, međusobno variraju među sobom.

Nakon što se odsimulira MPC metoda, dobiju se odzivi izlaznih varijabli, prikazani na slici 5.21. b. pod točkom 5.1.11.

4. Ispitivanje stabilnosti sustava

Na analogan način kao i u prethodnom koraku iteracije, za matematički model sustava (u prostoru stanja), simulira se ispitivanje stabilnosti izravnom metodom Ljapunova. Računalni model je kreiran u računalnom programu *MATLAB* [137].

Pritom se koriste iste utjecajne varijable, koje su prikazane u tablici 5.8. Rezultat ispitivanja stabilnosti sustava prikazan je na slici 5.21. c.

5. Kreiranje neizrazitih pravila ponašanja i njihov grafički prikaz

Na osnovu podataka dobivenih MPC metodom, te ispitivanja stabilnosti sustava, uz podatke iz matematičkog modela sustava, kreira se Mamdani model neizrazite logike.

U tu svrhu koristi se sustav za odlučivanje u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139]. Semantika utjecajnih varijabli, prikazana je u tablici 5.9. Slika 5.20. prikazuje definirana neizrazita pravila ponašanja u koraku iteracije 4.

Rezultati lokalnog i globalnog zaključivanja prikazani su u dobivenim rezultatima na slici 5.22.

Tablica 5.9. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koraku iteracije 4)

a)	<table> <tr> <th>n_M [min⁻¹]</th><th>Raspon</th><th>Semantika</th></tr> <tr> <td>600 – 1000</td><td>0</td><td>Vrlo malo</td></tr> <tr> <td>1000 – 1500</td><td>0.25</td><td>Malo</td></tr> <tr> <td>1500 – 2000</td><td>0.5</td><td>Srednje</td></tr> <tr> <td>2000 – 2500</td><td>0.75</td><td>Veliko</td></tr> <tr> <td>2500 – 3000</td><td>1</td><td>Vrlo veliko</td></tr> </table>	n_M [min ⁻¹]	Raspon	Semantika	600 – 1000	0	Vrlo malo	1000 – 1500	0.25	Malo	1500 – 2000	0.5	Srednje	2000 – 2500	0.75	Veliko	2500 – 3000	1	Vrlo veliko	b)	<table> <tr> <th>i [-]</th><th>Raspon</th><th>Semantika</th></tr> <tr> <td>200 – 240</td><td>0</td><td>Vrlo malo</td></tr> <tr> <td>240 – 280</td><td>0.25</td><td>Malo</td></tr> <tr> <td>300 – 340</td><td>0.5</td><td>Srednje</td></tr> <tr> <td>340 – 380</td><td>0.75</td><td>Veliko</td></tr> <tr> <td>380 – 400</td><td>1</td><td>Vrlo veliko</td></tr> </table>	i [-]	Raspon	Semantika	200 – 240	0	Vrlo malo	240 – 280	0.25	Malo	300 – 340	0.5	Srednje	340 – 380	0.75	Veliko	380 – 400	1	Vrlo veliko
n_M [min ⁻¹]	Raspon	Semantika																																					
600 – 1000	0	Vrlo malo																																					
1000 – 1500	0.25	Malo																																					
1500 – 2000	0.5	Srednje																																					
2000 – 2500	0.75	Veliko																																					
2500 – 3000	1	Vrlo veliko																																					
i [-]	Raspon	Semantika																																					
200 – 240	0	Vrlo malo																																					
240 – 280	0.25	Malo																																					
300 – 340	0.5	Srednje																																					
340 – 380	0.75	Veliko																																					
380 – 400	1	Vrlo veliko																																					
c)	<table> <tr> <th>m_T [t]</th><th>Raspon</th><th>Semantika</th></tr> <tr> <td>10 – 12</td><td>0</td><td>Vrlo malo</td></tr> <tr> <td>12 – 14</td><td>0.25</td><td>Malo</td></tr> <tr> <td>14 – 16</td><td>0.5</td><td>Srednje</td></tr> <tr> <td>16 – 18</td><td>0.75</td><td>Veliko</td></tr> <tr> <td>18 – 20</td><td>1</td><td>Vrlo veliko</td></tr> </table>	m_T [t]	Raspon	Semantika	10 – 12	0	Vrlo malo	12 – 14	0.25	Malo	14 – 16	0.5	Srednje	16 – 18	0.75	Veliko	18 – 20	1	Vrlo veliko	d)	<table> <tr> <th>v_T [m/s]</th><th>Raspon</th><th>Semantika</th></tr> <tr> <td>13.9 – 16.7</td><td>0</td><td>Vrlo malo</td></tr> <tr> <td>16.7 – 19.4</td><td>0.25</td><td>Malo</td></tr> <tr> <td>19.4 – 22.2</td><td>0.5</td><td>Srednje</td></tr> <tr> <td>22.2 – 25</td><td>0.75</td><td>Veliko</td></tr> <tr> <td>25 – 27.8</td><td>1</td><td>Vrlo veliko</td></tr> </table>	v_T [m/s]	Raspon	Semantika	13.9 – 16.7	0	Vrlo malo	16.7 – 19.4	0.25	Malo	19.4 – 22.2	0.5	Srednje	22.2 – 25	0.75	Veliko	25 – 27.8	1	Vrlo veliko
m_T [t]	Raspon	Semantika																																					
10 – 12	0	Vrlo malo																																					
12 – 14	0.25	Malo																																					
14 – 16	0.5	Srednje																																					
16 – 18	0.75	Veliko																																					
18 – 20	1	Vrlo veliko																																					
v_T [m/s]	Raspon	Semantika																																					
13.9 – 16.7	0	Vrlo malo																																					
16.7 – 19.4	0.25	Malo																																					
19.4 – 22.2	0.5	Srednje																																					
22.2 – 25	0.75	Veliko																																					
25 – 27.8	1	Vrlo veliko																																					
e)	<table> <tr> <th>ρ [-]</th><th>Raspon</th><th>Semantika</th></tr> <tr> <td>0 – 0.2</td><td>0</td><td>Vrlo malo</td></tr> <tr> <td>0.2 – 0.4</td><td>0.25</td><td>Malo</td></tr> <tr> <td>0.4 – 0.6</td><td>0.5</td><td>Srednje</td></tr> <tr> <td>0.6 – 0.8</td><td>0.75</td><td>Veliko</td></tr> <tr> <td>0.8 – 1</td><td>1</td><td>Vrlo veliko</td></tr> </table>	ρ [-]	Raspon	Semantika	0 – 0.2	0	Vrlo malo	0.2 – 0.4	0.25	Malo	0.4 – 0.6	0.5	Srednje	0.6 – 0.8	0.75	Veliko	0.8 – 1	1	Vrlo veliko																				
ρ [-]	Raspon	Semantika																																					
0 – 0.2	0	Vrlo malo																																					
0.2 – 0.4	0.25	Malo																																					
0.4 – 0.6	0.5	Srednje																																					
0.6 – 0.8	0.75	Veliko																																					
0.8 – 1	1	Vrlo veliko																																					

Dobiveni rezultati bit će još prokomentirani pod točkom 5.1.11.

1. If (nM is vrlo_veliko) and (i is veliko) and (mT is veliko) and (vV is vrlo_veiko) then (stabilnost_sustava is nestabilno) (1)
2. If (nM is vrlo_malo) and (i is vrlo_veliko) and (mT is vrlo_veiko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
3. If (nM is vrlo_malo) and (i is vrlo_veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
4. If (nM is malo) and (i is vrlo_veiko) and (mT is vrlo_veiko) and (vV is vrlo_veiko) then (stabilnost_sustava is nestabilno) (1)
5. If (nM is malo) and (i is veliko) and (mT is veliko) and (vV is vrlo_veiko) then (stabilnost_sustava is nestabilno) (1)
6. If (nM is malo) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
7. If (nM is malo) and (i is srednje) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
8. If (nM is malo) and (i is srednje) and (mT is srednje) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
9. If (nM is malo) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
10. If (nM is srednje) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
11. If (nM is srednje) and (i is srednje) and (mT is vrlo_veiko) and (vV is vrlo_veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
12. If (nM is veliko) and (i is srednje) and (mT is vrlo_veiko) and (vV is vrlo_veliko) then (stabilnost_sustava is asimptotski_stabilno) (1)
13. If (nM is veliko) and (i is srednje) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
14. If (nM is veliko) and (i is veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
15. If (nM is veliko) and (i is veliko) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
16. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is veliko) and (vV is veliko) then (stabilnost_sustava is nestabilno) (1)
17. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is srednje) and (vV is srednje) then (stabilnost_sustava is asimptotski_stabilno) (1)
18. If (nM is vrlo_veliko) and (i is vrlo_veliko) and (mT is malo) and (vV is malo) then (stabilnost_sustava is asimptotski_stabilno) (1)

Slika 5.20. Definirana neizrazita pravila ponašanja u koraku iteracije 4

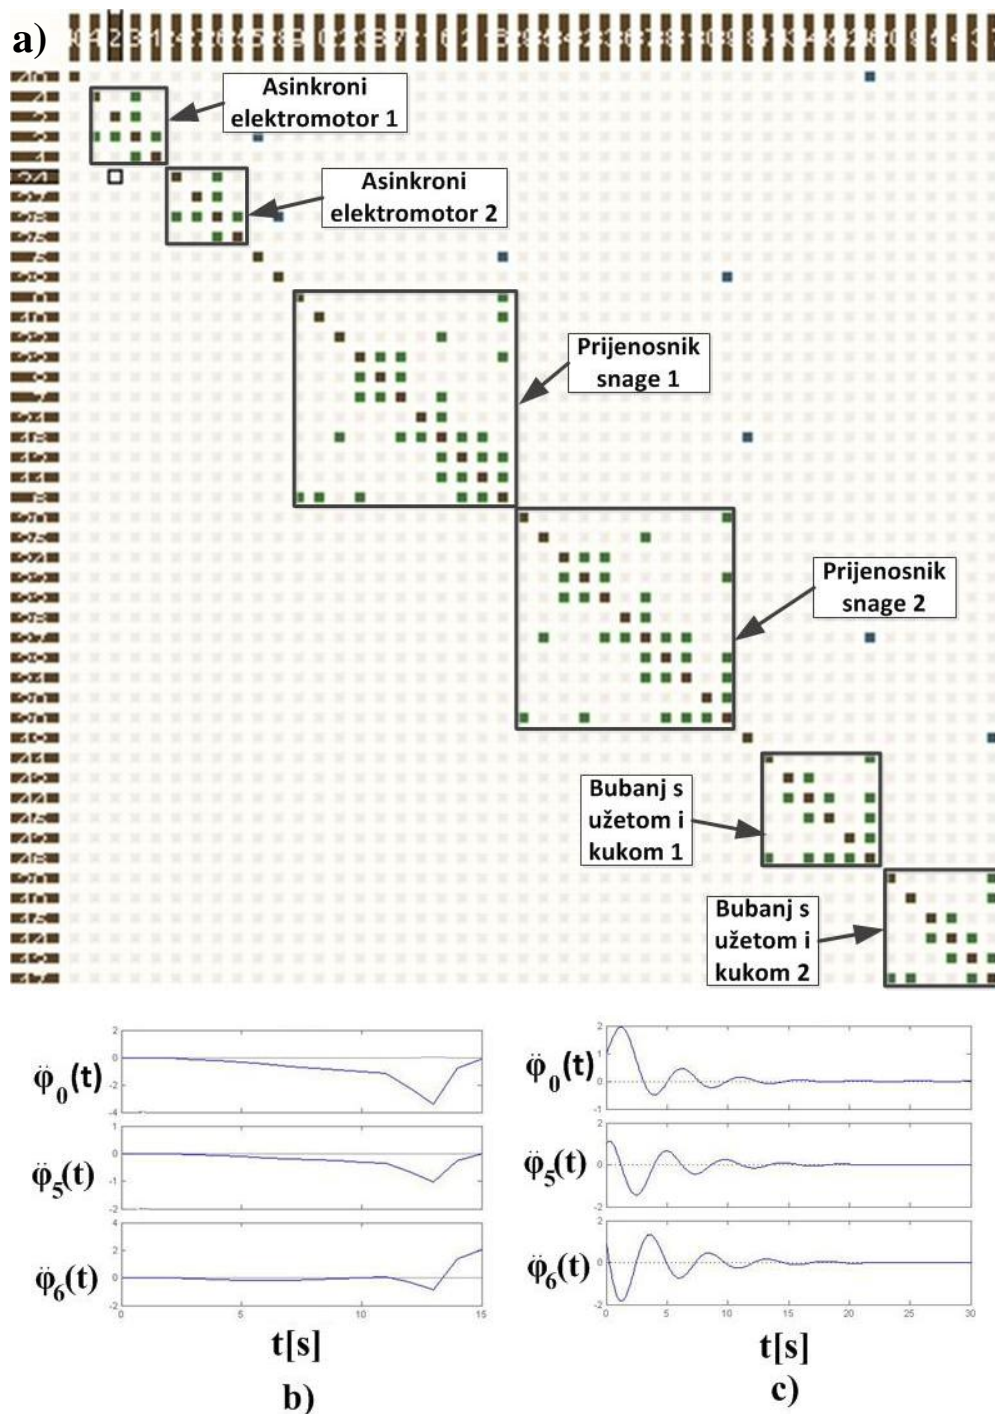
Promjenom neizrazitih pravila ponašanja uređaja za dizanje tereta (slici 5.20.) postignuto je da se promatrani sustav ponaša asimptotski stabilno i u slučajevima raspona velih brzina vrtnja elektromotora n_M , kod srednjih ukupnih prijenosnih omjera i , i to u slučaju vrlo velikih masa tereta m_T , te u slučaju velikih brzina vjetra v_V .

6. Zapis neizrazitih pravila ponašanja

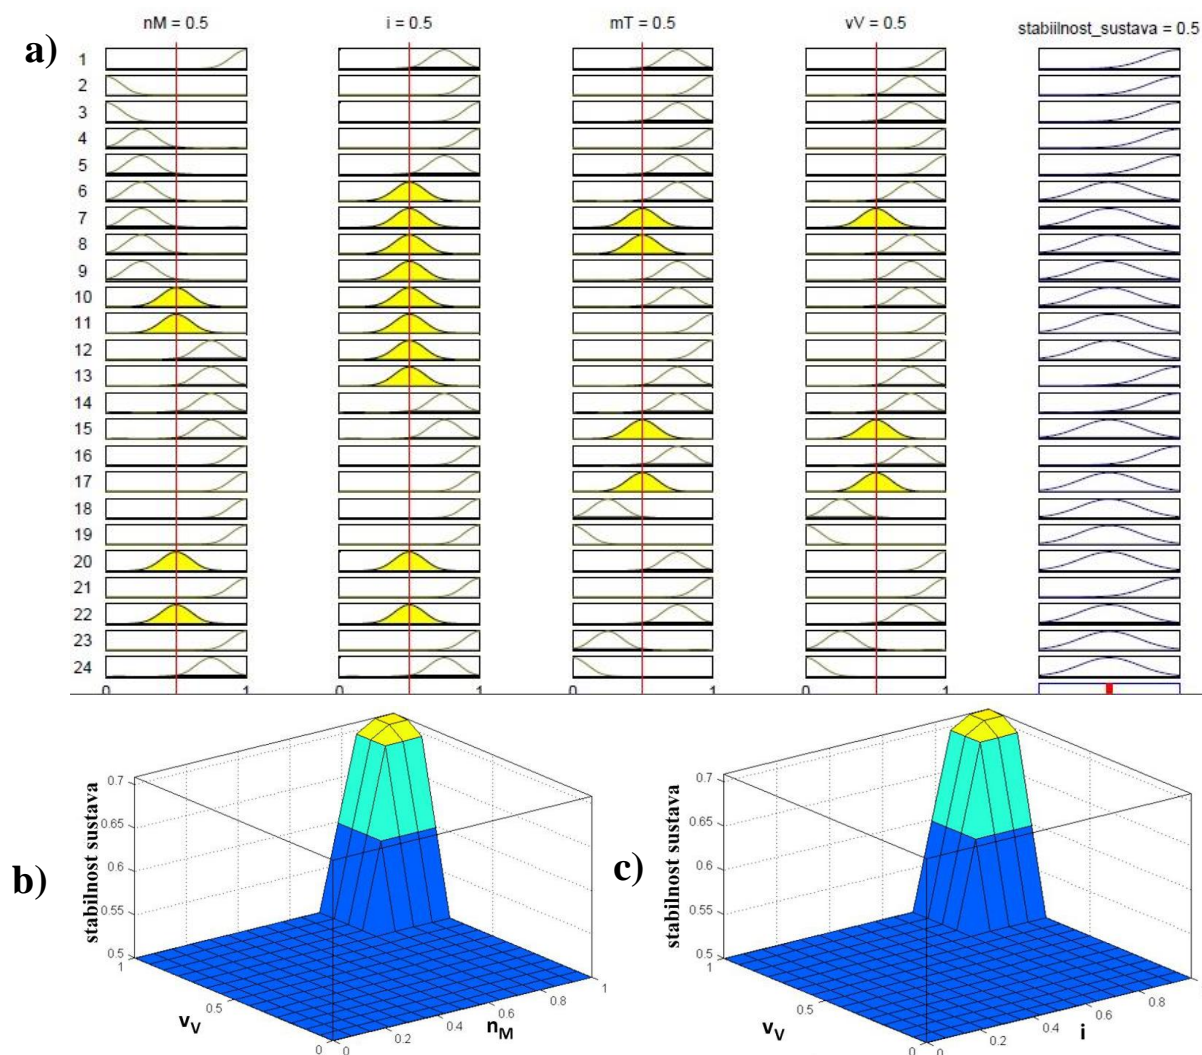
Neizrazita pravila ponašanja sustava zapisati će se u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139] u obliku *fis* datoteke.

Na slici 5.21. b i c prikazani su odzivi izlaznih varijabli (kod MPC metode, odnosno kod izravne metode Ljapunova), kad se promatrani sustav ponaša asimptotski stabilno.

5.1.11. Dobiveni rezultati nakon koraka iteracije 4



Slika 5.21. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova



Slika 5.22. Dobiveni rezultati za arhitekturu sustava uređaja za dizanje tereta; a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable n_M i v_V , c) rezultati globalnog zaključivanja za ulazne varijable i i v_V

Rezultati globalnog zaključivanja (slika 5.22. b i c) daje nam iste rezultate kao i u prethodnom koraku iteracije 3. Prema slici 5.22. b vidi se da se asimptotski stabilan sustav postiže u slučaju vrlo velikih brzina okretaja elektromotora za slučaj vrlo velikih brzina vjetra. Slika 5.22. c nam prikazuje da su potrebni vrlo veliki prijenosni omeri da bi se postigao asimptotski stabilan rad sustava, kod vrlo velikih brzina vjetra.

5.1.12. Tablični prikaz rezultata nakon koraka iteracije 4

Tablica 5.10. daje tablični prikaz rezultata na kraju koraka iteracije 4 za pojedine korake pristupa. Prema neizrazitim pravilima ponašanja može se uočiti da se sustav također ponaša nestabilno u slučajevima malih i vrlo velikih brzina vrtnje elektromotora, uz velike prijenosne omjere, mase tereta i brzine vjetra.

U posljednjem koraku iteracije 4, promijenjena su pravila ponašanja uređaja za dizanje. To je provedeno na način da je dodan još jedan sustav sa potpuno istim podsustavima, kao što je onaj u koraku iteracije 3. Time se želi ostvariti mogućnost istovremenog dizanja/spuštanja većih tereta [125], uz istovremeni rad oba sustava.

Tablica 5.10. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 4

Arhitektura sustava	Dva sustava sa istim podsustavima: trofazni asinkroni elektromotor, jednostavni planetarni prijenosnik sa pogonskim i gonjenim vratilom, spojke na pogonskom i gonjenom vratilu i ležajevi, bubanj za dizanje s čeličnim užetom i kukom za prihvat tereta
Matematički model sustava	Sustav običnih linearnih diferencijalnih jednačbi, dobivenih nakon postupka linearizacije (prikazan u prostoru stanja)
MPC metoda	Moguće je postići kvalitetnu simulaciju ponašanja sustava, osim u nestabilnom području
Ispitivanje stabilnosti sustava	Sustav pokazuje nestabilno ponašanje u slučajevima malih i vrlo velikih brzina vrtnji elektromotora, uz velike prijenosne omjere, mase tereta i brzine vjetra

5.2. Primjena algoritma u razvoju toplinsko-hidrauličnog sustava

Kao drugi primjer za verifikaciju predloženog algoritma, odabran je toplinsko – hidraulični sustav (klima komora) koji služi pripremi zraka u poslovnim objektima (kao što su trgovački centri, kongresni centri, poslovne zgrade itd.) [140]. Ovaj primjer je odabran iz razloga da bi se verifikacija provela na primjeru složenog tehničkog sustava, koji je izrazito linearan. Možemo ga tako promatrati uz određene pretpostavke. Navedeni sustav se također klasificira i u skupinu sustava sa procesima s izrazitim vremenskim kašnjenjem, tj. u skupinu jako sporih procesa.

Klima komora je tehnički sustav koji mora osigurati komforne uvjete klimatiziranih prostora (čistoću, temperaturu i vlažnost zraka) kombinacijom pojedinih procesa: filtriranje, grijanje, dogrijavanje, hlađenje i vlaženje zraka [141].

Izvodi se kao kombinacija različitih funkcionalnih jedinica (tehničkih podsustava), u skladu sa standardom EN 1886 za klima komore u zgradama [142].

5.2.1. Korak iteracije 1

Na temelju danih zahtjeva kupaca, te iz njih kreiranih inženjerskih zahtjeva, uz kataloške podatke proizvođača sličnih sustava, predlaže se se u prvom koraku iteracije početna (inicijalna) arhitektura klima komore. Ona se sastoji od slijedećih podsustava: grijača zraka, hladnjaka zraka, tlačnog i odsisnog ventilatora, te tlačnog i odsisnog voda (prikazano na slici 5.23.).

1. Opisivanje arhitekture sustava

Zahtjevi kupaca su slijedeći:

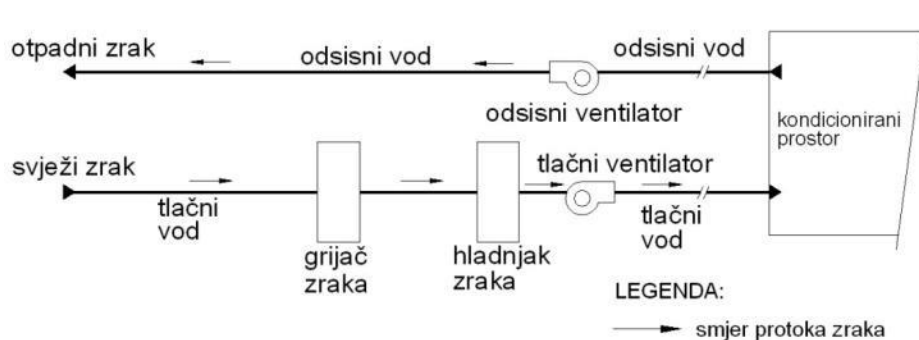
- uređaj mora imati osiguran neprekidni rad tokom cijelog dana,
- uređaj mora moći raditi u promjenjivim vanjskim uvjetima rada,
- uređaj mora biti otporan na atmosferske utjecaje (vodu, kišu, snijeg, led i zrak),
- uređaj mora imati mogućnost vanjske ugradnje (smještaj na krov objekta),
- mora biti osiguran tihi rad uređaja,
- mora se osigurati automatsko upravljanje radom klima komore,
- uređaj mora osigurati komforne uvjete u klimatiziranim prostorima poslovnog objekta.

Inženjerski zahtjevi su slijedeći:

- uređaj mora imati mogućnost rada u zimskom i ljetnom režimu,
- uređaj mora moći raditi pri temperaturi okoline: -35°C do 40°C ,
- mora se osigurati neprekidni priključak na električnu energiju $3\times 220\text{ V}$, 50 Hz ,
- temperatura ogrjevnog medija je $80/60^{\circ}\text{C}$ (sustavi grijača i dogrijača klima komore),
- temperatura rashladnog medija je $7/12^{\circ}\text{C}$ (sustav hladnjaka klima komore),
- temperatura ubacivanog svježeg zraka zimi ne smije prelaziti 25°C , a ljeti 19°C ,
- temperature u poslovnom prostoru treba odabrati u skladu sa standardom za trgovačke prostore,
- mora biti otporna na udare i vibracije,
- oplata klima uređaja, mora biti plastificirana,

- mora se osigurati stabilnost klima komore u radu,
- za pripremu ogrjevnog medija (topla voda za grijač zraka) u poslovnom objektu, predviđena je kotlovnica ložena prirodnim plinom za proizvodnju tople vode 80/60 °C,
- za potrebe pripreme rashladnog medija (tj. hladne vode za hladnjak klima komore), na krovu objekta se predviđa zrakom hlađeni kondenzator, za temperaturu hladne vode $\vartheta_{hv} = 7/12$ °C. U rashladnoj stanici predviđa se rashladnik za unutarnju ugradnju, koji će koristiti freon R 407 C, za održavanje temperature hladne vode.

U prvom koraku kreće se sa najjednostavnijim arhitekturom sustava, kojom možemo osigurati sve zahtijevane inženjerske zahtjeve za traženi uporabni prostor.



Slika 5.23. Početna (inicijalna) arhitektura sustava klima komore (korak iteracije 1)


Prema početnoj arhitekturi sustava, opisuje se matričnim zapisom arhitektura sustava pomoću matrice komponenata DSM. U tu svrhu koristiti će se računalni program *LOOME0* [128]. Rezultat matričnog prikaza arhitekture sustava početne arhitekture sustava klima komore prikazan je pod točkom 5.2.2. s dobivenim rezultatima na slici 5.27. a.

2. Kreiranje matematičkog modela ponašanja sustava

Pretpostavke koje se uvode kod modeliranja pojedinih podsustava klima komore [143] su slijedeće:

- pretpostavlja se da je cjelokupni sustav, a time i svi njegovi podsustavi dobro izolirani od bilo kakvih utjecaja okoline, tj. može se reći da nema gubitaka topline prema okolini,
- strujanje fluida (zrak i voda) unutar sustava klima komore, kao i svih njegovih podsustava je laminarno,

- iako je izmjena topline u sustavima izmjenjivača topline klima komore prostorna, za naše opisivanje promjena temperatura fluida, pretpostaviti ćemo da ovisi samo o jednoj koordinati, tj. da je jednodimenzionalna,
- u sustavu su zanemareni svi mehanički, hidraulički i toplinski gubici, pretpostavlja se savršeno miješanje recirkulirajućeg zraka sa svježim zrakom,
- raspodjela zraka u kanalima tokom strujanja je savršena, te se kompletan sustav, kao i sve njegove podsustave, promatra kao sustave sa koncentriranim parametrima. Time dobivamo jednostavne modele, koji nam još uvijek dovoljno dobro opisuju procese unutar samog sustava. Procesne veličine su stoga funkcija samo jedne varijable, vremena t ,
- izmjenjivači topline (rekuperatori) izvide se kao pločasti izmjenjivači ([145], [146]), no ovdje ih se radi pojednostavljenja, promatra kao tip izmjenjivača „cijev u cijevi“ ([143], [144]),
- tlačni i odsisni ventilator rade sa konstantnom brzinom vrtnje.



Slika 5.24. Shema grijača zraka za kreiranje matematičkog modela podsustava (zimsko razdoblje rada)

Na osnovu uvedenih pretpostavki, kreira se pojednostavljena shema grijača zraka (vidi sliku 5.24.), kao i pojednostavljena shema hladnjaka zraka (vidi sliku 5.25.).

Legenda (prema slici 5.24.):

q_z [kg/s] – maseni protok zraka; $q_z = \text{konst.}$

q_v [kg/s] – maseni protok vode; $q_v = \text{konst.}$

T_{zu} [K] – ulazna temperatura zraka

T_{zi} [K] – izlazna temperature zraka

T_{vu} [K] – ulazna temperature tople vode

T_{vi} [K] – izlazna temperature tople vode

T_s [K] – temperature cijevne stijenke

$\Phi_o = 0$ W – toplinski tok prema okolini; nema izmjene topline sa okolinom

Pri kreiranju matematičkog modela grijača zraka koristi se jednadžba održanja energije (topline).

Počinje se sa postavljanjem jednadžbe toplinskog toka koji prelazi sa tople struje (oznaka T – topla voda) na hladnu struju (oznaka H – zrak) u izmjenjivaču topline, na beskonačno malom djeliću izmjenjivačke površine dA ([143], [144]):

$$d\Phi_{TH} = \alpha_{TH} \cdot (T_T(A) - T_H(A)) \cdot dA \quad (5.58.),$$

gdje su:

$d\Phi_{TH}$ [W] – toplinski tok kroz djelić izmjenjivačke površine dA ,

$T_T(A)$ [K] – temperatura toplog medija na promatranom djeliću izmjenjivačke površine dA ,

$T_H(A)$ [K] – temperatura hladnog medija na promatranom djeliću izmjenjivačke površine dA ,

α_{TH} [W/m²K] – koeficijent prijelaza topline između toplog i hladnog medija – pretpostavlja se da je konstantan po cijeloj izmjenjivačkoj površini,

A [m²] – izmjenjivačka površina.

Integriranjem izraza (5.58.) po cijeloj izmjenjivačkoj površini dobiva se ukupni toplinski tok:

$$\Phi_{TH} = \alpha_{TH} \cdot \int_0^A (T_T(A) - T_H(A)) \cdot dA \quad (5.59.).$$

Temperature toplog i hladnog medija unutar izmjenjivača općenito ovise o geometrijskoj koordinati. Kod matematičkog modela s koncentriranim parametrima [144], temperature $T_T(A)$ i $T_H(A)$ mogu se zamijeniti srednjim vrijednostima:

$$T_T = \frac{T_{TU} + T_{TI}}{2} \text{ [K]} \quad (5.60.),$$

$$T_H = \frac{T_{HU} + T_{HI}}{2} \text{ [K]} \quad (5.61.),$$

gdje su:

T_T [K] – srednja temperatura toplog medija (voda) unutar izmjenjivača,

T_H [K] – srednja temperatura hladnog medija (zraka) unutar izmjenjivača.

Uvrštenjem izraza (5.60.) i (5.61.) u izraz (5.59.) dobiva se:

$$\Phi_{TH} = \alpha_{TH} \cdot (T_T - T_H) \cdot A \text{ [W]} \quad (5.62.).$$

Promjena entalpije računa se kao razliku dovedene i odvedene energije (toplinskog toka) prema slijedećem izrazu, uz pretpostavku da nema unutarnjih toplinskih izvora ili ponora:

$$dE = dE_1 - dE_2 \text{ [J]} \quad (5.63.),$$

gdje su:

dE [J] – promjena entalpije promatranog volumena medija u vremenu dt ,

dE_1 [J] – količina topline dovedena promatranom volumena medija u vremenu dt ,

dE_2 [J] – količina topline odvedena promatranom volumena medija u vremenu dt .

Ukupnu entalpiju (toplinsku energiju) koja je akumulirana u određenom volumenu medija, prikazuje se izrazom:

$$E = m \cdot c \cdot T = \rho \cdot V \cdot c \cdot T \text{ [J]} \quad (5.64.),$$

gdje su:

E [J] – entalpija (ukupna toplinska energija), akumulirana u promatranom volumenu medija,

m [kg] – masa promatranog volumena medija,

c [J/kgK] – specifični toplinski kapacitet medija,

T [K] – temperatura medija,

V [m³] – volumen medija,

ρ [kg/m³] – gustoća medija.

Derivacijom entalpije po vremenu dobiva se promjena toplinskog toka:

$$\frac{dE}{dt} = \Phi_1 - \Phi_2 = \varrho \cdot V \cdot c \cdot \frac{dT}{dt} \quad (5.65.),$$

gdje su:

Φ_1 [W] – toplinski tok doveden mediju,

Φ_2 [W] – toplinski tok odveden mediju.

Korištenjem jednadžbe (5.65.), može se napisati energetska jednadžbu za zrak, toplu vodu i pregradnu stijenu u izmjenjivaču topline.

Jednadžba energetske ravnoteže za toplu vodu (topliju struju), se piše uz pretpostavku da se toploj vodi odvodi toplinski tok koji je jednak razlici toplinskih tokova tople vode na ulazu i izlazi izmjenjivača, te odvodi toplinski tok koji s tople vode prijeđe na stijenku cijevi.

$$\frac{dE_T}{dt} = \Phi_{TU} - \Phi_{TI} - \Phi_{Ts} = \varrho_T \cdot V_T \cdot c_T \cdot \frac{dT_T}{dt} \quad (5.66.),$$

gdje su:

$$\Phi_{TU} = \varrho_T \cdot c_T \cdot q_T \cdot T_{TU} \text{ [W]} - \text{toplinski tok tople vode na ulazu u izmjenjivač} \quad (5.67.),$$

$$\Phi_{TI} = \varrho_T \cdot c_T \cdot q_T \cdot T_{TI} \text{ [W]} - \text{toplinski tok tople vode na izlazu iz izmjenjivača} \quad (5.68.),$$

$$\Phi_{Ts} = \alpha_{Ts} \cdot A_T \cdot (T_T - T_s) \text{ [W]} - \text{toplinski tok koji topla voda preda stijenci cijevi} \quad (5.69.).$$

$A_T \text{ [m}^2\text{]}$ – izmjenjivačka površina tople vode i stijenske cijevi,

$T_T \text{ [K]}$ – srednja vrijednost temperature tople vode unutar izmjenjivača (računa se prema izrazu (5.60.),

$T_s \text{ [K]}$ – srednja temperatura stijenske izmjenjivača.

Uvrštavanjem izraza (5.67.), (5.68.) i (5.69.) u izraz (5.66.) dobivamo:

$$\varrho_T \cdot V_T \cdot c_T \cdot \frac{dT_T}{dt} = \varrho_T \cdot c_T \cdot q_{TU} \cdot (T_{TU} - T_{TI}) - \alpha_{Ts} \cdot A_T \cdot (T_T - T_s) \quad (5.70.).$$

Jednadžba energetske ravnoteže za zrak (hladniju struju), izvodi se na analogan način kao i izraz (5.66.). Pritom se uzima pretpostavka da se volumenu zraka unutar izmjenjivača dovodi toplinski tok, koji sa hladne vode prijeđe na stijenku cijevi, te odvodi toplinski tok jednak razlici toplinskih tokova na ulazu i izlazu izmjenjivača:

$$\frac{dE_H}{dt} = \Phi_{HU} - \Phi_{HI} + \Phi_{Hs} = \varrho_H \cdot V_H \cdot c_H \cdot \frac{dT_H}{dt} \quad (5.71.),$$

gdje su:

$$\Phi_{HU} = \varrho_H \cdot c_H \cdot q_{HU} \cdot T_{HU} \text{ [W]} - \text{toplinski tok zraka na ulazu u izmjenjivač} \quad (5.72.),$$

$$\Phi_{HI} = \varrho_H \cdot c_H \cdot q_{HU} \cdot T_{HI} \text{ [W]} - \text{toplinski tok zraka na izlazu iz izmjenjivača} \quad (5.73.),$$

$$\Phi_{Hs} = \alpha_{Hs} \cdot A_H \cdot (T_s - T_H) \text{ [W]} - \text{toplinski tok koji stijenske cijevi preda zraku} \quad (5.74.).$$

$A_H \text{ [m}^2\text{]}$ – izmjenjivačka površina zraka i stijenske cijevi,

$T_H \text{ [K]}$ – srednja vrijednost temperature zraka unutar izmjenjivača (računa se prema izrazu (5.61.)),

$T_s \text{ [K]}$ – srednja temperatura stijenske izmjenjivača.

Uvrštavanjem izraza (5.72.), (5.73.) i (5.74.) u izraz (5.71.) dobivamo:

$$\varrho_H \cdot V_H \cdot c_H \cdot \frac{dT_H}{dt} = \varrho_H \cdot c_H \cdot q_H \cdot (T_{HU} - T_{HI}) + \alpha_{HS} \cdot A_H \cdot (T_s - T_H) \quad (5.75.).$$

Jednadžba energetske ravnoteže za cijevnu stijenku izmjenjivača dana je izrazom:

$$\frac{dE_s}{dt} = \Phi_{Ts} - \Phi_{Hs} = \varrho_s \cdot V_s \cdot c_s \cdot \frac{dT_s}{dt} \quad (5.76.).$$

Matematički model grijača zraka može se zapisati slijedećim jednadžbama:

$$\frac{dT_T}{dt} = a_1 \cdot q_T \cdot (T_{TU} - T_{TI}) - a_2 \cdot (T_T - T_s) \quad (5.77.),$$

$$\frac{dT_H}{dt} = c_1 \cdot q_H \cdot (T_{HU} - T_{HI}) + c_2 \cdot (T_s - T_H) \quad (5.78.),$$

$$\frac{dT_s}{dt} = b_1 \cdot (T_T - T_s) - b_2 \cdot (T_s - T_H) \quad (5.79.),$$

gdje su koeficijenti $a_1, b_1, c_1, a_2, b_2, c_2$ dani slijedećim jednadžbama:

$$a_1 = \frac{1}{V_T}, \quad a_2 = \frac{\alpha_{Ts} \cdot A_T}{\rho_T \cdot c_T \cdot V_T} \quad (5.80.),$$

$$c_1 = \frac{1}{V_H}, \quad c_2 = \frac{\alpha_{HS} \cdot A_H}{\rho_H \cdot c_H \cdot V_H} \quad (5.81.),$$

$$b_1 = \frac{\alpha_{Ts} \cdot A_T}{\rho_s \cdot c_s \cdot V_s}, \quad b_2 = \frac{\alpha_{HS} \cdot A_H}{\rho_s \cdot c_s \cdot V_s} \quad (5.82.).$$

Parametri u koeficijentima (5.80.) – (5.82.), određuju se prema jednadžbama ([135], [147], [148]). Jednadžbe (5.77.) – (5.79.), mogu se prikazati u zapisu u prostoru stanja (prema jednadžbama (4.9.) i (4.10.) – vidi poglavlje 4):

$$\dot{x}(t) = \mathbf{A}x(t) + \mathbf{B}u(t)$$

$$y(t) = \mathbf{C}x(t) + \mathbf{D}u(t)$$

Dotične jednadžbe se raspišu u obliku (promatramo da su izlazne temperature tople i hladnije struje, te temperatura stijenke ovisne o vremenu, tj. nestacionarne):

$$\frac{dT_{TI}(t)}{dt} = -(a_1 \cdot q_T + \frac{1}{2} \cdot a_2) \cdot T_{TI}(t) + (a_1 \cdot q_T - \frac{1}{2} \cdot a_2) \cdot T_{TU} + a_2 \cdot T_s(t) \quad (5.83.),$$

$$\frac{dT_{HI}(t)}{dt} = -(c_1 \cdot q_H + \frac{1}{2} \cdot c_2) \cdot T_{HI}(t) + (c_1 \cdot q_H - \frac{1}{2} \cdot c_2) \cdot T_{HU} + c_2 \cdot T_s(t) \quad (5.84.),$$

$$\frac{dT_s(t)}{dt} = \frac{1}{2} \cdot b_2 \cdot T_{TI}(t) + \frac{1}{2} \cdot b_1 \cdot T_{HI}(t) - (b_1 + b_2) \cdot T_s(t) + \frac{1}{2} \cdot b_2 \cdot T_{TU} + \frac{1}{2} \cdot b_1 \cdot T_{HU} \quad (5.85.)$$

Prema jednadžbama ((5.83.) – (5.85.)) dajemo slijedeće prikaze za varijable za model prostora stanja:

a) vektor derivacije stanja:

$$\dot{\mathbf{x}}(t) = \begin{bmatrix} \frac{dT_{TI}(t)}{dt} \\ \frac{dT_{HI}(t)}{dt} \\ \frac{dT_s(t)}{dt} \end{bmatrix} \quad (5.86.),$$

b) matrica dinamike sustava:

$$\mathbf{A} = \begin{bmatrix} -(a_1 \cdot q_T + \frac{1}{2} \cdot a_2) & 0 & a_2 \\ 0 & -(c_1 \cdot q_H + \frac{1}{2} \cdot c_2) & c_2 \\ \frac{1}{2} \cdot b_2 & \frac{1}{2} \cdot b_1 & -(b_1 + b_2) \end{bmatrix} \quad (5.87.),$$

c) vektor stanja:

$$\mathbf{x}(t) = \begin{bmatrix} T_{TI}(t) \\ T_{HI}(t) \\ T_s(t) \end{bmatrix} \quad (5.88.),$$

d) matrica raspodjele upravljanja sustavom:

$$\mathbf{B} = \begin{bmatrix} a_1 \cdot q_T - \frac{1}{2} \cdot a_2 & 0 \\ 0 & -(c_1 \cdot q_H + \frac{1}{2} \cdot c_2) \\ 0 & 0 \end{bmatrix} \quad (5.89.),$$

e) vektor pobuda na sustav:

$$\mathbf{u}(t) = \begin{bmatrix} T_{TU} \\ T_{HU} \end{bmatrix} \quad (5.90.),$$

f) matrica mjerenja (senzora) sustava:

$$\mathbf{C} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \quad (5.91.),$$


g) matrica izravnog prolaza pobude na izlaz sustava:

$$\mathbf{D} = \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \quad (5.92.).$$

Na osnovu prikazanih varijabli, kreira se model zapisa sustava u prostoru stanja, tj. programski kod u računalnom program *MATLAB* [137].

Matematički model hladnjaka zraka kreira se na analogan način (prema shemi hladnjaka zraka na slici 5.25.). Mogu se primijeniti iste jednačbe kao i kod podsustava grijača zraka ((5.80.) – (5.85.)), kao i one u zapisu prostora stanja ((5.86.) – (5.92.)).

No treba naglasiti da je ovdje toplija struja medij zrak, koji se hladi tj. predaje toplinski tok hladnoj vodi (koristi se dogovor o konvenciji predznaka za toplinske tokove) [145].



Slika 5.25. Shema hladnjaka zraka za kreiranje matematičkog modela podsustava (ljetno razdoblje rada)

Legenda (prema slici 5.25.):

q_z [kg/s] – maseni protok zraka; $q_z = \text{konst.}$

q_v [kg/s] – maseni protok vode; $q_v = \text{konst.}$

T_{zu} [K] – ulazna temperature zraka

T_{zi} [K] – izlazna temperature zraka

T_{vu} [K] – ulazna temperature tople vode

T_{vi} [K] – izlazna temperature tople vode

T_s [K] – temperature cijevne stijenke;

$\Phi_o = 0$ W – toplinski tok prema okolini; nema izmjene topline sa okolinom

3. Simuliranje sustava korištenjem MPC metode

Na temelju kreiranog modela u prostoru stanja (u računalnom programu MATLAB), simulira se ponašanje sustava MPC metodom. U MPC metodi koriste se utjecajne varijable koje su prikazane u tablici 5.11.

Kao što se vidi iz dane tablice, utjecajne varijable su: T_v [°C] – vanjska temperatura (a), q_z [m³/s] – volumni protok zraka (b), varijante sustava sa geometrijom: $B \times H$ [mm²] (c) i težinski faktor ρ [-] (d).

Model MPC metode kreiran je u računalnom programu *MATLAB Model Predictive Control Toolbox* [138] i to uz pomoć potprograma *MPC Design Tool*.

Utjecajne varijable su odabrane na temelju procjene konstruktora, koji smatra da one imaju najveći utjecaj na ponašanje promatranog sustava. Varijable se tokom analize ponašanja sustava u MPC metodi međusobno variraju među sobom. Na osnovu dobivenih rezultata u kasnijem koraku, kreiraju se neizrazita pravila ponašanja.

Uz odabir parametara MPC metode, simuliraju se odzivi izlaznih varijabli sustava. Želi se pravilnim odabirom parametara postići da se dobije kvalitetna simulacija ponašanja sustava.

Za određeni skup utjecajnih parametara, prikazani su odzivi sustava za zimsko razdoblje na slici 5.27. b.

4. Ispitivanje stabilnosti sustava

Za matematički model sustava danog u prostoru stanja, simulira se ispitivanje stabilnosti izravnom metodom Ljapunova. Model je kreiran u računalnom programu *MATLAB* [137]. Pritom se koriste iste utjecajne varijable (kao i u prethodnoj operaciji algoritma), koje su prikazane u tablici 5.11. Rezultat ispitivanja stabilnosti sustava prikazan je na slici 5.27. c.

Tablica 5.11. Prikaz raspona utjecajnih varijabli (u koracima iteracije 1 i 2)

a)

T_v [°C]
-35 – 40

b)

q_z [m ³ /s]
0.2 – 7.8

c)

Broj varijante	B x H [mm ²]	Broj varijante	B x H [mm ²]
1	700 x 450	7	1300 x 1100
2	1000 x 450	8	1300 x 1350
3	700 x 650	9	1600 x 1350
4	700 x 750	10	1600 x 1700
5	1000 x 750	11	1950 x 1700
6	1000 x 1100		

d)

ρ [-]
0 – 1

5. Kreiranje neizrazitih pravila ponašanja i njihov grafički prikaz

Na osnovu podataka dobivenih MPC metodom, te ispitivanja stabilnosti sustava, uz podatke iz matematičkog modela sustava, kreira se Mamdani model neizrazite logike. U tu svrhu koristi se sustav za odlučivanje u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139]. Semantika utjecajnih varijabli, koje koristimo kod kreiranja neizrazitih pravila u koracima iteracije 1 i 2 prikazana je u tablici 5.12.

Lokalno odlučivanje daje nam sheme odlučivanja, dok nam globalno zaključivanje daje trodimenzionalni (3D) prikaz odabranih dviju ulaznih varijabli i jedne izlazne varijable. Izlazna varijabla je u ovom slučaju podatak je li sustav asimptotski stabilan ili nestabilan za prikazanu semantiku ulaznih varijabli. Koristi se Mamdani model odlučivanja neizrazitom logikom.

Rezultati lokalnog i globalnog zaključivanja prikazani su u dobivenim rezultatima na slici 5.28. Dobiveni rezultati za svaki korak iteracije biti će još prokomentirani pod točkom 5.2.2.

Na slici 5.26. prikazana su definirana neizrazita pravila ponašanja u koraku iteracije 1.

Tablica 5.12. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koracima iteracije 1 i 2)

a)

T_v [°C]	Raspon	Semantika
-35 – -15	0	Vrlo malo
-15 – -5	0.25	Malo
-5 – 10	0.5	Srednje
10 – 20	0.75	Veliko
20 – 40	1	Vrlo veliko

b)

q_z [m ³ /s]	Raspon	Semantika
0.2 – 1.25	0	Vrlo malo
1.25 – 3.6	0.25	Malo
3.6 – 4.6	0.5	Srednje
4.6 – 5.8	0.75	Veliko
5.8 – 7.8	1	Vrlo veliko

c)

Broj varijante	Raspon	Semantika
1 – 2	0	Vrlo malo
2 – 4	0.25	Malo
4 – 6	0.5	Srednje
6 – 8	0.75	Veliko
8 – 11	1	Vrlo veliko

d)

Broj varijante	$B \times H$ [mm ²]	Broj varijante	$B \times H$ [mm ²]
1	700 x 450	7	1300 x 1100
2	1000 x 450	8	1300 x 1350
3	700 x 650	9	1600 x 1350
4	700 x 750	10	1600 x 1700
5	1000 x 750	11	1950 x 1700
6	1000 x 1100		

e)

ρ [-]	Raspon	Semantika
0 – 0.2	0	Vrlo malo
0.2 – 0.4	0.25	Malo
0.4 – 0.6	0.5	Srednje
0.6 – 0.8	0.75	Veliko
0.8 – 1	1	Vrlo veliko

6. Zapis neizrazitih pravila ponašanja

Neizrazita pravila ponašanja sustava zapisati će se u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139] u obliku *fis* datoteke.

```

1. If (Tv is vrlo_malo) and (qz is vrlo_malo) and (BxH is vrlo_malo) and (TF is vrlo_malo) then (sustav-korak_iteracije_1 is nestabilno) (1)
2. If (Tv is vrlo_malo) and (qz is vrlo_malo) and (BxH is malo) and (TF is malo) then (sustav-korak_iteracije_1 is nestabilno) (1)
3. If (Tv is malo) and (qz is malo) and (BxH is malo) and (TF is malo) then (sustav-korak_iteracije_1 is nestabilno) (1)
4. If (Tv is malo) and (qz is malo) and (BxH is srednje) and (TF is srednje) then (sustav-korak_iteracije_1 is nestabilno) (1)
5. If (Tv is srednje) and (qz is malo) and (BxH is srednje) and (TF is srednje) then (sustav-korak_iteracije_1 is nestabilno) (1)
6. If (Tv is srednje) and (qz is srednje) and (BxH is srednje) and (TF is srednje) then (sustav-korak_iteracije_1 is asimotski_stabilno) (1)
7. If (Tv is srednje) and (qz is srednje) and (BxH is srednje) and (TF is veliko) then (sustav-korak_iteracije_1 is asimotski_stabilno) (1)
8. If (Tv is veliko) and (qz is srednje) and (BxH is srednje) and (TF is veliko) then (sustav-korak_iteracije_1 is asimotski_stabilno) (1)
9. If (Tv is srednje) and (qz is veliko) and (BxH is srednje) and (TF is veliko) then (sustav-korak_iteracije_1 is nestabilno) (1)
10. If (Tv is srednje) and (qz is srednje) and (BxH is veliko) and (TF is veliko) then (sustav-korak_iteracije_1 is nestabilno) (1)
11. If (Tv is veliko) and (qz is veliko) and (BxH is veliko) and (TF is veliko) then (sustav-korak_iteracije_1 is nestabilno) (1)
12. If (Tv is veliko) and (qz is vrlo_veliko) and (BxH is veliko) and (TF is veliko) then (sustav-korak_iteracije_1 is nestabilno) (1)
13. If (Tv is veliko) and (qz is veliko) and (BxH is vrlo_veliko) and (TF is vrlo_veliko) then (sustav-korak_iteracije_1 is nestabilno) (1)
14. If (Tv is vrlo_veliko) and (qz is veliko) and (BxH is veliko) and (TF is vrlo_veliko) then (sustav-korak_iteracije_1 is nestabilno) (1)
15. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is vrlo_veliko) and (TF is vrlo_veliko) then (sustav-korak_iteracije_1 is nestabilno) (1)
16. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is veliko) and (TF is vrlo_veliko) then (sustav-korak_iteracije_1 is nestabilno) (1)

```

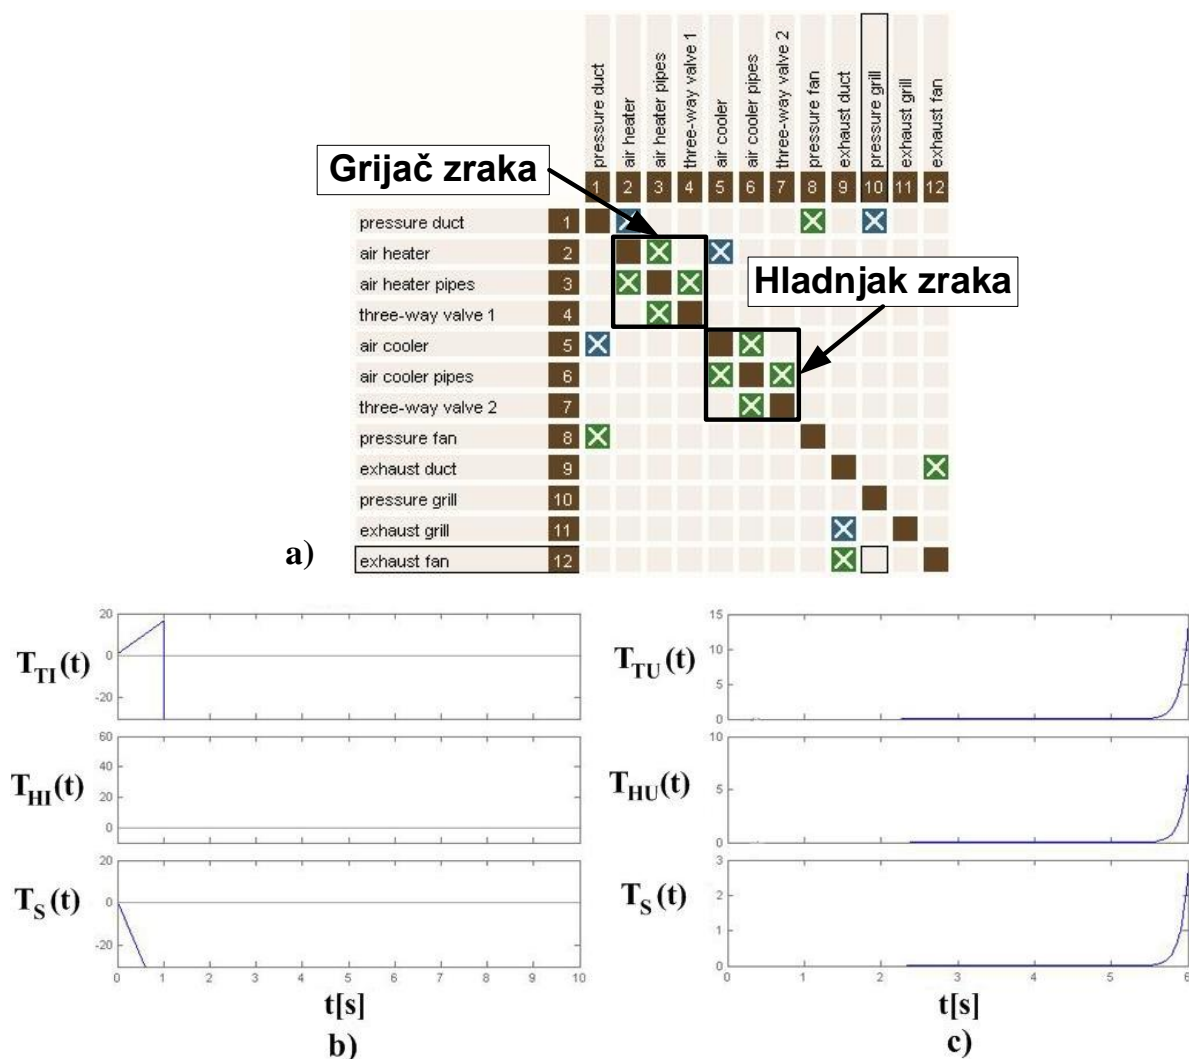
Slika 5.26. Definirana neizrazita pravila ponašanja u koraku iteracije 1

Prema definiranim neizrazitim pravilima ponašanja na slici 5.26. može se primjetiti da se promatrani sustav klima komore ponaša asimptotski stabilno jedino u slučajevima raspona srednjih i velikih vanjskih temperatura T_V , te kod srednjih protoka zraka q_z , i to u slučaju srednje geometrije klima komore BxH . U većini ostalih slučajeva promatrani sustav se ponaša nestabilno.

Na slici 5.27. prikazani su rezultati dobiveni u koraku iteracije 1. Na a) slici prikazan je matrični zapis arhitekture sustava dobiven matricom komponenata DSM. Na slikama b) dan je prikaz odziva izlaznih varijabli dobiven MPC metodom, dok je pod c) dan prikaz odziva varijabli kod ispitivanja stabilnosti sustava.


Slika 5.28. prikazuje rezultate dobivene zaključivanjem na bazi neizrazite logike. Na a) slici prikazan je skup svih raspodjela funkcija pripadnosti za unesena neizrazita pravila u sustav odlučivanja (lokalno zaključivanje). Na slikama b) i c) dan je prikaz globalnog zaključivanja za dva skupa odabranih ulaznih varijabli, vanjske temperature i protoka zraka, T_V i q_z , te protoka zraka i geometrije klima komore, q_z i BxH .

5.2.2. Dobiveni rezultati nakon koraka iteracije 1



Slika 5.27. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 1); a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.27. b daje nam grafički prikaz odziva izlaznih varijabli korištenjem MPC metode, dok nam slika 5.27. c prikazuje grafički odzive istih varijabli sustava na početne uvjete, korištenjem izravne metode Ljapunova. Na slici 5.27. b i c prikazani su slučajevi odziva izlaznih varijabli sustava kad se promatrani sustav ponaša nestabilno.



Slika 5.28. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 1); a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable T_V i q_z , c) rezultati globalnog zaključivanja za ulazne varijable q_z i BxH

Kao primjer ulaznih varijabli za globalno zaključivanje u ovom primjeru odabrane su (slika 5.28. b) protok zraka q_A i vanjska temperatura T_V , dok su u drugom slučaju (slika 5.6. c) to ulazne varijable geometrija klima komore BxH i protok zraka q_z . Sa slike 5.6. b je vidljivo da se asimptotski stabilan sustav postiže u slučaju srednjih raspona protoka zraka za slučaj srednjih i velikih vanjskih temperatura zraka. Slika 5.6. c nam opet prikazuje da se asimptotski stabilan slučaj postiže u kombinaciji srednje geometrije klima komore i kod malih i srednjih protoka zraka.

5.2.3. Tablični prikaz rezultata nakon koraka iteracije 1

Dan je tablični prikaz na kraju koraka iteracije 1 za pojedine operacije algoritma. Prema neizrazitim pravilima ponašanja može se uočiti da najveći utjecaj na nestabilno ponašanje sustava ima vanjska temperatura T_v , u rasponu od $-35 - -25$ °C, zbog vrlo velikog koeficijenta prijelaza topline α , kod tako niske temperature zraka.

Drugi veliki utjecaj na stabilnost sustava, imaju velike brzine strujanja, odnosno veliki volumni protoci zraka q_z , (kod manjih geometrija klima komore, pritom mislimo na površinu poprečnog presjeka komore $B \times H$).

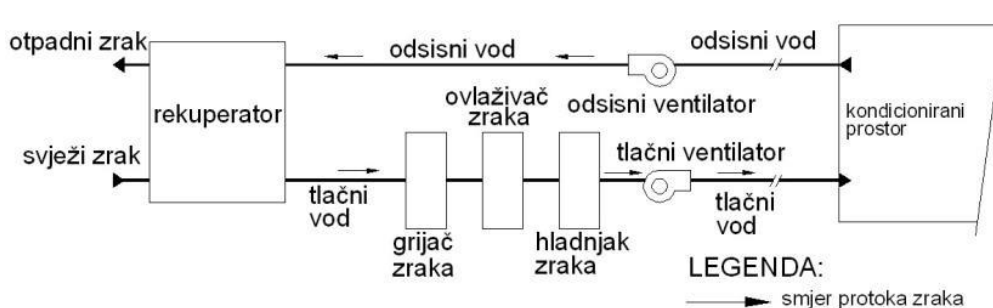
Tablica 5.13. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 1

Arhitektura sustava	Podsustavi: grijač zraka, hladnjak zraka, tlačni vod, odsisni vod, tlačni ventilator, odsisni ventilator
Matematički model ponašanja sustava	Sustav običnih linearnih diferencijalnih jednadžbi (prikaz u prostoru stanja)
MPC metoda	Moguće je postići kvalitetnu simulaciju ponašanja sustava, osim u nestabilnom području
Ispitivanje stabilnosti sustava	Sustav pokazuje nestabilno ponašanje u većini slučajeva

5.2.4. Korak iteracije 2

U drugom koraku iteracije početna arhitektura klima komore, proširena je za dva podsustava: rekuperator zraka i ovlaživač zraka. Rekuperatorom se smanjuje toplinski kapacitet grijača zraka, a samim time se povećava i ulazna temperatura u grijač zraka [141]. Time smo željeli utjecati na to da dobijemo stabilan sustav pri radu s niskim vanjskim temperaturama. Ovlaživač zraka je dodan sa svrhom povećanja sadržaja vlage u sustavu, njime se ne povećava nikakvu energija (prikazano na slici 5.29.).

1. Opisivanje arhitekture sustava



Slika 5.29. Arhitektura sustava klima komore (korak iteracije 2)

Na osnovu predložene arhitekture sustava, opisuju se mogući podsustavi klima komore pomoću matrice komponenata DSM, a prikazani su u dobivenim rezultatima (nakon koraka iteracije 2) na slici 5.33. a. U tu svrhu korišten je računalni program *LOOME* [128].


2. Kreiranje matematičkog modela ponašanja sustava

Prema dobivenim podsustavima pomoću DSM-a, pristupa se izradi matematičkog modela ponašanja podsustava. U nastavku će biti kreirani samo matematički modeli ponašanja onih podsustava, koji nisu kreirani u prethodnom koraku iteracije 1.

Počinja se sa postavljanjem jednadžba energetske ravnoteže za pločasti rekuperator topline. Ona nam pokazuje da je promjena toplinskog toka u rekuperatoru, jednaka promjeni toplinskog toka otpadnog zraka (toplija struja), odnosno promjeni toplinskog toka svježeg zraka (hladnija struja). Kaže se da se u rekuperatoru pritom vrši povrat topline (prikazano na slici 5.8.):

$$\frac{dE_R}{dt} = \frac{dE_T}{dt} = \frac{dE_H}{dt} \quad (5.93.).$$

Kod ovlaživača zraka, nema nikakve promjene energije, tj. topline, pošto se radi o adijabatskom ovlaživanju pri $h = \text{konst.}$ [145]. No ovdje se mora voditi računa o promjeni sadržaja vlage Δx tokom procesa ovlaživanja.



Slika 5.30. Shema rekuperatora zraka za kreiranje matematičkog modela podsustava

Legenda (prema slici 5.30.):

q_{sz} [kg/s] – maseni protok svježeg zraka; $q_{sz} = \text{konst.}$

q_{oz} [kg/s] – maseni protok otpadnog zraka; $q_{oz} = \text{konst.}$

T_{szu} [K] – ulazna temperatura svježeg zraka


T_{szi} [K] – izlazna temperatura svježeg zraka

T_{ozu} [K] – ulazna temperatura otpadnog zraka

T_{ozi} [K] – izlazna temperatura otpadnog zraka

Φ [W] – toplinski tok izmijenjen u rekuperatoru topline

Nadalje, kreiran je matematički model ponašanja podsustava ovlaživača zraka. Proces ovlaživanja zraka se može promatrati kao adijabatsko ubrizgavanje vodene pare u vlažni zrak [145]. Pod pojmom adijabatsko, podrazumijeva se da se radi o ravnotežnom procesu, te da tokom procesa nema izmjene toplinskog toka sa okolinom, tj. $\Phi_o = 0$ (izolirano mješalište), prikazano na slici 5.31.).



Slika 5.31. Shema ovlaživača zraka za kreiranje matematičkog modela podsustava

Legenda (prema slici 5.31.):

q_{mzu} [kg/s] – ulazni maseni protok vlažnog zraka; $q_{mzu} = \text{konst.}$

q_{mzi} [kg/s] – izlazni maseni protok vlažnog zraka; $q_{mzi} = \text{konst.}$

q_{wv} [kg/s] – maseni protok vodene pare; $q_{wv} = \text{konst.}$

h_{mzu} [J/kg] – specifična entalpija vlažnog zraka na ulazu

h_{mzi} [J/kg] – specifična entalpija vlažnog zraka na izlazu

h_{wv} [J/kg] – specifična entalpija vodene pare

x_{mzu} [kg/kg] – sadržaj vlage u vlažnom zraku na ulazu

x_{mzi} [kg/kg] – sadržaj vlage u vlažnom zraku na izlazu

x_{wv} [kg/kg] – sadržaj vlage u vodenoj pari

$\Phi_o = 0$ W – toplinski tok prema okolini; nema izmjene topline sa okolinom

Pošto se ovdje radi o tzv. otvorenom sustavu, jednadžba energetske ravnoteže, odnosno promjene energije u podsustavu, uz pretpostavku zanemarivanja potencijalne i kinetičke energije struja, poprima zapis:

$$\frac{dE}{dt} = \Phi_o = H_I - H_U \text{ [W]} \quad (5.94.),$$

gdje su:

Φ_o [W] – toplinski tok prema okolini,

H_I [W] – entalpija na izlazu iz podsustava,

H_U [W] – entalpija na ulazu u podsustav.

Kako tokom procesa nema izmjene toplinskog toka sa okolinom, tj. $\Phi_o = 0$, tada je:

$$H_I - H_U = 0 \quad (5.95.),$$

odnosno:

$$H_I = H_U \quad (5.96.).$$

Entalpije se izražavaju prema jednadžbama:

$$H_U = q_{mzu} \cdot h_{zu} + q_{mv} \cdot h_{wv} \text{ [W]} \quad (5.97.),$$

$$H_I = q_{mzi} \cdot h_{zi} \text{ [W]} \quad (5.98.).$$

Napomena: cirkulacijska pumpa vode ovlaživača zraka radi s konstantnim brojem okretaja.

Na osnovu prikazanih modela pojedinih podsustava (kao i onih u koraku iteracije 1), kreira se matematički model cjelokupnog sustava, koji se prikazuje u prostoru stanja.

3. Simuliranje sustava korištenjem MPC metode

Na temelju kreiranog matematičkog modela u prostoru stanja (u računalnom programu *MATLAB* [137]), simulira se ponašanje sustava MPC metodom, korištenjem potprograma *MPC Design Tool* unutar programa *MATLAB Model Predictive Toolbox* [138]. U MPC metodi koriste se utjecajne varijable koje su prikazane u tablici 5.11. Nakon što se odsimulira MPC metoda, dobiju se odzivi izlaznih varijabli sustava, prikazani na slici 5.33. b.

4. Ispitivanje stabilnosti sustava

Za matematički model sustava danog u prostoru stanja, simulira se ispitivanje stabilnosti izravnom metodom Ljapunova. Model je kreiran u računalnom programu *MATLAB* [137].

Pritom se koriste iste utjecajne varijable (kao i u prethodnom koraku iteracije 3), koje su prikazane u tablici 5.11. Rezultat ispitivanja stabilnosti sustava prikazan je na slici 5.33. c.

5. Kreiranje neizrazitih pravila ponašanja i njihov grafički prikaz

Na osnovu podataka dobivenih MPC metodom, te ispitivanja stabilnosti sustava, uz podatke iz matematičkog modela sustava, kreira se Mamdani model neizrazite logike. U tu svrhu koristi se sustav za odlučivanje u računalnom programu *MATLAB Fuzzy Logic Toolbox* [137]. Semantika utjecajnih varijabli, koje koristimo kod kreiranja neizrazitih pravila u koracima iteracije 1 i 2 prikazana je u tablici 5.12.

Rezultati lokalnog i globalnog zaključivanja prikazani su u dobivenim rezultatima na slici 5.34. Dobiveni rezultati bit će prokomentirani pod točkom 5.2.5.

Slika 5.32. prikazuje definirana pravila ponašanja u koraku iteracije 2.

1. If (Tv is vrlo_malo) and (qz is vrlo_malo) and (BxH is vrlo_malo) and (TF is vrlo_malo) then (korak_iteracije_2 is asimptotski_stabilno) (1)
2. If (Tv is vrlo_malo) and (qz is vrlo_malo) and (BxH is malo) and (TF is malo) then (korak_iteracije_2 is asimptotski_stabilno) (1)
3. If (Tv is malo) and (qz is malo) and (BxH is malo) and (TF is malo) then (korak_iteracije_2 is asimptotski_stabilno) (1)
4. If (Tv is malo) and (qz is malo) and (BxH is srednje) and (TF is srednje) then (korak_iteracije_2 is asimptotski_stabilno) (1)
5. If (Tv is srednje) and (qz is malo) and (BxH is srednje) and (TF is srednje) then (korak_iteracije_2 is asimptotski_stabilno) (1)
6. If (Tv is malo) and (qz is srednje) and (BxH is srednje) and (TF is srednje) then (korak_iteracije_2 is nestabilno) (1)
7. If (Tv is srednje) and (qz is srednje) and (BxH is srednje) and (TF is veliko) then (korak_iteracije_2 is nestabilno) (1)
8. If (Tv is veliko) and (qz is srednje) and (BxH is srednje) and (TF is veliko) then (korak_iteracije_2 is nestabilno) (1)
9. If (Tv is srednje) and (qz is veliko) and (BxH is srednje) and (TF is veliko) then (korak_iteracije_2 is nestabilno) (1)
10. If (Tv is srednje) and (qz is srednje) and (BxH is veliko) and (TF is veliko) then (korak_iteracije_2 is asimptotski_stabilno) (1)
11. If (Tv is veliko) and (qz is veliko) and (BxH is veliko) and (TF is veliko) then (korak_iteracije_2 is asimptotski_stabilno) (1)
12. If (Tv is veliko) and (qz is vrlo_veliko) and (BxH is veliko) and (TF is veliko) then (korak_iteracije_2 is asimptotski_stabilno) (1)
13. If (Tv is veliko) and (qz is veliko) and (BxH is vrlo_veliko) and (TF is veliko) then (korak_iteracije_2 is asimptotski_stabilno) (1)
14. If (Tv is vrlo_veliko) and (qz is veliko) and (BxH is veliko) and (TF is veliko) then (korak_iteracije_2 is asimptotski_stabilno) (1)
15. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is vrlo_veliko) and (TF is vrlo_veliko) then (korak_iteracije_2 is asimptotski_stabilno) (1)
16. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is veliko) and (TF is vrlo_veliko) then (korak_iteracije_2 is asimptotski_stabilno) (1)

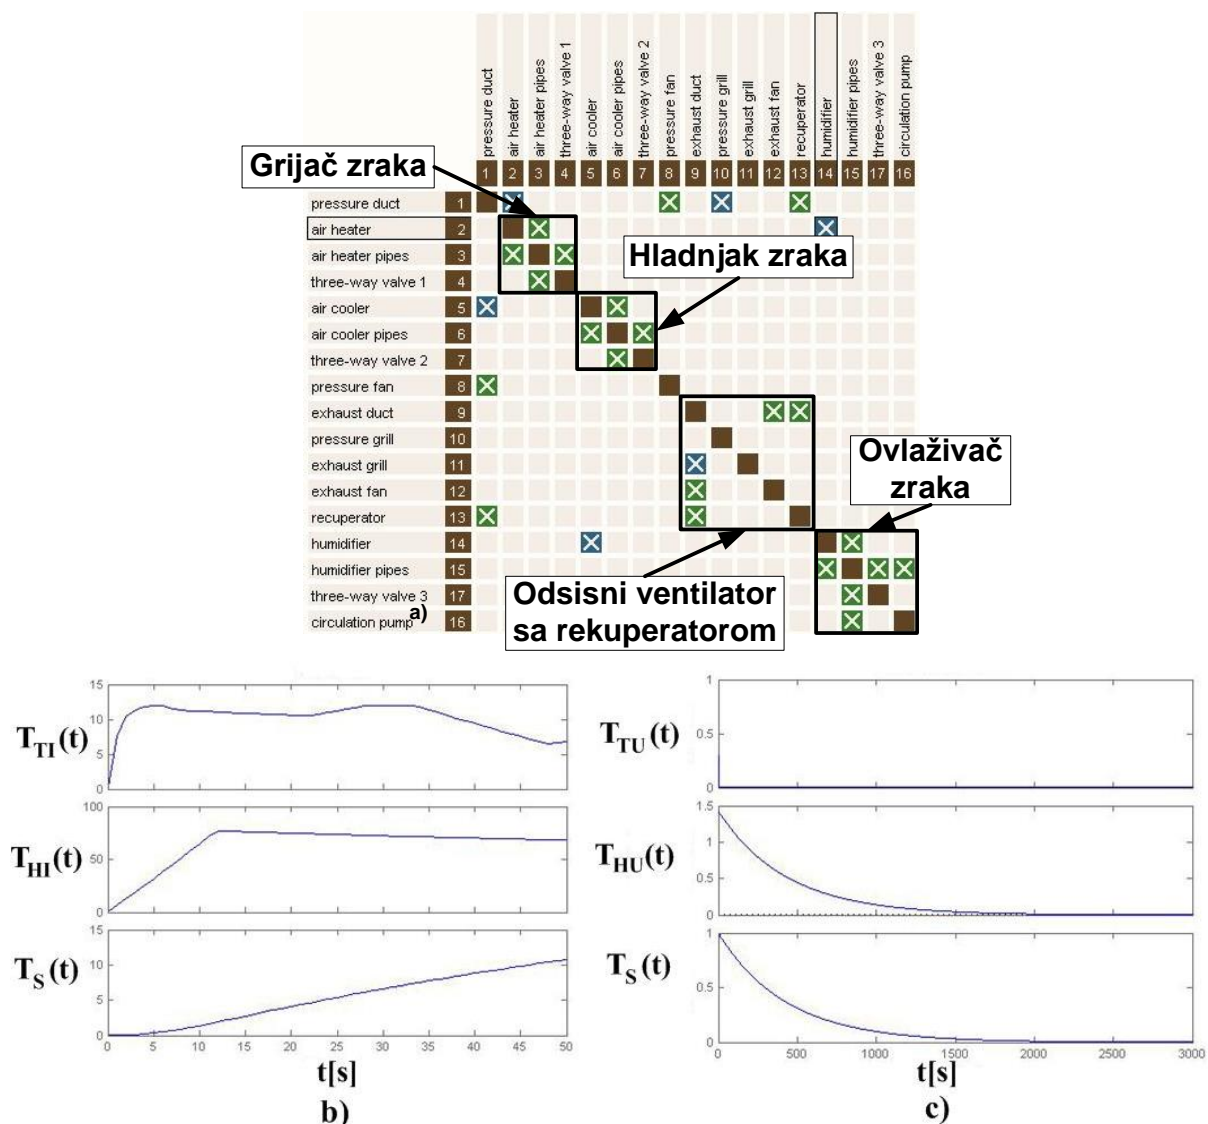
Slika 5.32. Definirana neizrazita pravila ponašanja u koraku iteracije 2

U odnosu na korak iteracije 1 prema definiranim neizrazitim pravilima ponašanja na slici 5.32. može se primjetiti da se promatrani sustav klima komore ponaša asimptotski stabilno i u slučajevima raspona vrlo malih i malih vanjskih temperatura T_V , i to kod vrlo malih i malih protoka zraka q_z , te u slučajevima vrlo male, male i srednje geometrije klima komore BxH . Također i u slučajevima velikih i vrlo velikih protoka zraka, uz raspon velikih geometrija klima komora postigli smo da se sustav također ponaša asimptotski stabilno. U većini ostalih slučajeva promatrani sustav se ponaša nestabilno.

6. Zapis neizrazitih pravila ponašanja


Neizrazita pravila ponašanja sustava zapisati će se u računalnom programu *MATLAB Fuzzy Logic Toolbox* u obliku *fis* datoteke [139].

5.2.5. Dobiveni rezultati nakon koraka iteracije 2



Slika 5.33. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 2); a) matrica komponenta DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.33. daje prikaz rezultata dobivenih u koraku iteracije 2. Na a) slici prikazan je rezultat matričnog prikaza arhitekture sustava dobiven matricom komponenta DSM, dok je na slikama b) dan prikaz odziva izlaznih varijabli dobiven MPC metodom, a pod c) prikaz odziva varijabli kod ispitivanja stabilnosti sustava. Na slici 5.33. b i c prikazani su slučajevi odziva izlaznih varijabli sustava kad se promatrani sustav ponaša asimptotski stabilno.



Slika 5.34. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 2); a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable T_v i q_z , c) rezultati globalnog zaključivanja za ulazne varijable q_z i $B \times H$

Kao i u prethodnom koraku, i ovdje je dan prikaz rezultata, dobiven zaključivanjem na bazi neizrazite logike na slici 5.34. Na a) slici prikazan je skup svih raspodjela funkcija pripadnosti za unesena neizrazita pravila u sustav odlučivanja (lokalno zaključivanje), dok slike b) i c) daju prikaz globalnog zaključivanja za dva skupa odabranih ulaznih varijabli (iste kao i u prethodnom koraku), vanjske temperature i protoka zraka, T_v i q_z , te protoka zraka i geometrije klima komore, q_z i $B \times H$. Na slici 5.34. b može se vidjeti da se asimptotski stabilan sustav postiže u slučajevima srednjih i velikih protoka zraka kod vrlo malih i malih vanjskih temperatura zraka.

Slika 5.34. c nam opet govori da se asimtotsko ponašanje sustava može postići i kod malih i srednjih geometrija klima komore uz velike i vrlo velike protoke zraka.

5.2.6. Tablični prikaz rezultata nakon koraka iteracije 2

Dan je tablični prikaz na kraju koraka iteracije 2 za pojedine operacije algoritma. Prema neizrazitim pravilima ponašanja može se uočiti kao i u prethodnom koraku iteracije, da najveći utjecaj na stabilnost sustava ima vanjska temperatura T_V , i to u rasponu od $-35 - -25$ °C. Tada ima vrlo veliki koeficijent prijelaza topline α . Također veliki utjecaj imaju i veliki protoci zraka q_z .


Tablica 5.14. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 2

Arhitektura sustava	Podsustavi: rekuperator topline, grijač zraka, ovlaživač zraka, hladnjak zraka, tlačni vod, odsisni vod, tlačni ventilator, odsisni ventilator
Matematički model sustava	Sustav običnih linearnih diferencijalnih jednadžbi (prikaz u prostoru stanja)
MPC metoda	Moguće je postići kvalitetnu simulaciju ponašanja sustava, osim u nestabilnom području
Ispitivanje stabilnosti sustava	Sustav pokazuje nestabilno ponašanje u slučajevima niskih vanjskih temperatura T_V i velikih protoka zraka q_z , kada zrak nastrujava na male poprečne presjeke kanala $B \times H$

5.2.7. Korak iteracije 3

U trećem koraku iteracije (prikazano na slici 5.35.), prethodna arhitektura sustava je proširena za nekoliko podsustava. Kao prvo dodan je recirkulacijski vod, sa ciljem smanjenja kapaciteta postojećih izmjenjivača topline, te iskorištenja topline iz otpadnog zraka [141]. Time je smanjen i ulazni protok zraka, pošto se svjež zrak miješa sa recirkulirajućim. Dodan je i obilazni (engl. “*by-pass*”) vod, kojim je moguće omogućiti rad klima komore u prijelaznom razdoblju (između zimskog i ljetnog razdoblja) [141]. Kao posljednji podsustav dodan je dogrijač zraka, koji smanjuje kapacitet grijača zraka, te omogućuje dogrijavanje, tj. ubacivanje svježeg zraka sa višom temperaturom u kondicionirani prostor. Time se željelo poboljšati stabilnost sustava kod niskih temperatura zraka.

1. Opisivanje arhitekture sustava




Slika 5.35. Arhitektura sustava klima komore (korak iteracije 3)

Matricom komponenata DSM dobiven je matični prikaz arhitekture sustava sa mogućim podsustavima (prikazano u dobivenim rezultatima na slici 5.39. a). Kao i u prethodnim koracima iteracije i ovdje je korišten računalni program *LOOME* [128].

2. Kreiranje matematičkog modela ponašanja sustava

Na slici 5.36. prikazana je shema rekuperatora zraka sa recirkulirajućim i obilaznim vodom za kreiranje matematičkog modela podsustava (zimsko i ljetno razdoblje rada). Dogrijač zraka je funkcionalno isti podsustav kao i grijач zraka, čiji je matematički model ponašanja izveden još u prvom koraku iteracije (vidi točku 5.2.1.), pa se ovdje ne izvodi.

Pretpostavka: tlačni i odsisni ventilator rade sa konstantnim brzinama vrtnje.



Slika 5.36. Shema rekuperatora zraka sa recirkulirajućim i obilaznim vodom za kreiranje matematičkog modela podsustava

Legenda (prema slici 5.36.):

q_{sz} [kg/s] – maseni protok svježeg zraka; $q_{sz} = \text{konst.}$

q_{oz} [kg/s] – maseni protok otpadnog zraka; $q_{oz} = \text{konst.}$

q_z [kg/s] – maseni protok svježeg zraka nakon miješanja sa recirkulirajućim zrakom; $q_{oz} = \text{konst.}$

T_{szu} [K] – ulazna temperatura svježeg zraka


T_{szi} [K] – izlazna temperatura svježeg zraka

T_{ozu} [K] – ulazna temperatura otpadnog zraka

T_M [K] – temperatura svježeg zraka nakon miješanja sa recirkulirajućim zrakom

Φ [W] – toplinski tok izmijenjen u rekuperatoru topline

Recirkulacijskim vodom, omogućeno je miješanje svježeg i otpadnog zraka u odgovarajućem omjeru, pa se na izlazu iz miješališta, odnosno na ulazu u grijač zraka dobije povišena temperatura, čime je smanjen toplinski kapacitet grijača zraka. U nastavku teksta je prikazan matematički model adijabatskog miješališta dviju struja vlažnog zraka.



Slika 5.37. Shema miješanja svježeg i recirkulirajućeg zraka

U podsustav miješališta zraka koje je izolirano (prikazano na slici 5.37.), ulaze dvije struje zraka: svježeg zraka, masenog protoka q_{mzR} [kg/s], specifične entalpije h_{zR} [J/kg] i sadržaja vlage x_{zR} [kg/kg], te recirkulirajućeg zraka masenog protoka q_{mzSZ} [kg/s], specifične entalpije h_{zSZ} [J/kg] i sadržaja vlage x_{zSZ} [kg/kg]. Iz miješališta izlazi struja vlažnog zraka, koji ima maseni protok q_{mzM} [kg/s], specifične entalpije h_{zM} [J/kg] i sadržaja vlage x_{zM} [kg/kg].

Ukupna entalpija ulaznih struja (svježeg i recirkulirajućeg zraka) i entalpija nastale mješavine (izlazna struja), su prema I glavnom stavku termodinamike jednake:

$$H_U = H_I \text{ [J]} \quad (5.99.),$$

gdje su:

$$H_U = q_{mzR} \cdot h_{zR} + q_{mzSZ} \cdot h_{zS} \text{ [J]} \quad (5.100.),$$

$$H_I = q_{mzM} \cdot h_{zM} \text{ [J]} \quad (5.101.).$$

3. Simuliranje sustava korištenjem MPC metode

Na temelju kreiranog matematičkog modela u prostoru stanja (u računalnom programu MATLAB [137]), simulira se ponašanje sustava MPC metodom korištenjem potprograma *MPC Design Tool* unutar programa *MATLAB Model Predictive Toolbox* [138]. U MPC metodi koriste se utjecajne varijable koje su prikazane u tablici 5.15. Nakon što se odsimulira MPC metoda, dobiju se odzivi izlaznih varijabli sustava, prikazani na slici 5.39. b.

Kao i u koracima iteracije 1 i 2 i ovdje se u MPC metodi, koriste utjecajne varijable sa rasponima, kako je to prikazano u tablici 5.5. Kao što se vidi prema danoj tablici utjecajne varijable su, kao i u koracima iteracije 1 i 2 iste: T_v [°C] – vanjska temperatura (a), q_z [m³/s] – volumni protok zraka (b), varijante sa geometrijom: $B \times H$ [mm²] (c) i težinski faktor ρ [-] – težinski faktor. Varijable se međusobno variraju, te se kasnije na osnovi dobivenih rezultata, kreiraju neizrazita pravila ponašanja. U ovom koraku iteracije proširuje se broj ispitivanih varijanti sustava sa njihovom geometrijom.

Tablica 5.15. Prikaz raspona utjecajnih varijabli (u koracima iteracije 3 i 4)

a)	<table><tr><td>T_v [°C]</td></tr><tr><td>-35 – 40</td></tr></table>	T_v [°C]	-35 – 40	b)	<table><tr><td>q_z [m³/s]</td></tr><tr><td>0.2 – 27.8</td></tr></table>	q_z [m ³ /s]	0.2 – 27.8																																
T_v [°C]																																							
-35 – 40																																							
q_z [m ³ /s]																																							
0.2 – 27.8																																							
c)	<table> <tr> <th>Broj varijante</th><th>$B \times H$ [mm²]</th><th>KK</th><th>$B \times H$ [mm²]</th></tr> <tr><td>1</td><td>700 x 450</td><td>9</td><td>1600 x 1350</td></tr> <tr><td>2</td><td>1000 x 450</td><td>10</td><td>1600 x 1700</td></tr> <tr><td>3</td><td>700 x 650</td><td>11</td><td>1950 x 1700</td></tr> <tr><td>4</td><td>700 x 750</td><td>12</td><td>1950 x 2000</td></tr> <tr><td>5</td><td>1000 x 750</td><td>13</td><td>2200 x 2000</td></tr> <tr><td>6</td><td>1000 x 1100</td><td>14</td><td>2200 x 2300</td></tr> <tr><td>7</td><td>1300 x 1100</td><td>15</td><td>2500 x 2300</td></tr> <tr><td>8</td><td>1300 x 1350</td><td>16</td><td>2500 x 2600</td></tr> </table>	Broj varijante	$B \times H$ [mm ²]	KK	$B \times H$ [mm ²]	1	700 x 450	9	1600 x 1350	2	1000 x 450	10	1600 x 1700	3	700 x 650	11	1950 x 1700	4	700 x 750	12	1950 x 2000	5	1000 x 750	13	2200 x 2000	6	1000 x 1100	14	2200 x 2300	7	1300 x 1100	15	2500 x 2300	8	1300 x 1350	16	2500 x 2600		
Broj varijante	$B \times H$ [mm ²]	KK	$B \times H$ [mm ²]																																				
1	700 x 450	9	1600 x 1350																																				
2	1000 x 450	10	1600 x 1700																																				
3	700 x 650	11	1950 x 1700																																				
4	700 x 750	12	1950 x 2000																																				
5	1000 x 750	13	2200 x 2000																																				
6	1000 x 1100	14	2200 x 2300																																				
7	1300 x 1100	15	2500 x 2300																																				
8	1300 x 1350	16	2500 x 2600																																				
d)	<table><tr><td>ρ [-]</td></tr><tr><td>0 – 1</td></tr></table>	ρ [-]	0 – 1																																				
ρ [-]																																							
0 – 1																																							

4. Ispitivanje stabilnosti sustava

Za matematički model sustava danog u prostoru stanja, simulira se ispitivanje stabilnosti izravnom metodom Ljapunova. Matematički model je kreiran u računalnom programu *MATLAB* [137].

Pritom se koriste iste utjecajne varijable (kao i u prethodnom koraku algoritma 3), koje su prikazane u tablici 5.15. Rezultat ispitivanja stabilnosti sustava prikazan je na slici 5.39. c.

5. Kreiranje neizrazitih pravila ponašanja i njihov grafički prikaz

Kao i u prethodnom koraku iteracije, na osnovu podataka dobivenih MPC metodom, te ispitivanja stabilnosti sustava, uz podatke iz matematičkog modela sustava, kreira se Mamdani model neizrazite logike. U tu svrhu koristi se sustav za odlučivanje u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139]. Semantika utjecajnih varijabli, koje koristimo kod kreiranja neizrazitih pravila u koracima iteracije 3 i 4 prikazana je u tablici 5.16. Slika 5.38. prikazuje definirana neizrazita pravila ponašanja u koraku iteracije 3.

Rezultati lokalnog i globalnog zaključivanja prikazani su u dobivenim rezultatima na slici 5.40. Dobiveni rezultati bit će još prokomentirani u poglavlju 6, pod točkom 5.2.8.

Tablica 5.16. Prikaz semantike utjecajnih varijabli za kreiranje neizrazitih pravila (u koracima iteracije 3 i 4)

a)	$T_v [^{\circ}\text{C}]$	Raspon	Semantika
	-35 – -15	0	Vrlo malo
	-15 – -5	0.25	Malo
	-5 – 10	0.5	Srednje
	10 – 20	0.75	Veliko
	20 – 40	1	Vrlo veliko

b)	$q_z [\text{m}^3/\text{s}]$	Raspon	Semantika
	0.2 – 1.25	0	Vrlo malo
	1.25 – 3.6	0.25	Malo
	3.6 – 7.8	0.5	Srednje
	7.8 – 13.9	0.75	Veliko
	13.9 – 27.8	1	Vrlo veliko

c)	Broj varijante	Raspon	Semantika
	1 – 3	0	Vrlo malo
	3 – 6	0.25	Malo
	6 – 9	0.5	Srednje
	9 – 12	0.75	Veliko
	12 – 16	1	Vrlo veliko

d)	Broj varijante	$B \times H [\text{mm}^2]$	KK	$B \times H [\text{mm}^2]$
	1	700 x 450	9	1600 x 1350
	2	1000 x 450	10	1600 x 1700
	3	700 x 650	11	1950 x 1700
	4	700 x 750	12	1950 x 2000
	5	1000 x 750	13	2200 x 2000
	6	1000 x 1100	14	2200 x 2300
	7	1300 x 1100	15	2500 x 2300
	8	1300 x 1350	16	2500 x 2600

f)	$\rho [-]$	Raspon	Semantika
	0 – 0.2	0	Vrlo malo
	0.2 – 0.4	0.25	Malo
	0.4 – 0.6	0.5	Srednje
	0.6 – 0.8	0.75	Veliko
	0.8 – 1	1	Vrlo veliko


```

1. If (Tv is vrlo_malo) and (qz is vrlo_malo) and (BxH is vrlo_malo) and (TF is vrlo_malo) then (korak_iteracije_3 is asimptotski_stabilno) (1)
2. If (Tv is malo) and (qz is malo) and (BxH is malo) and (TF is vrlo_malo) then (korak_iteracije_3 is asimptotski_stabilno) (1)
3. If (Tv is srednje) and (qz is srednje) and (BxH is srednje) and (TF is malo) then (korak_iteracije_3 is asimptotski_stabilno) (1)
4. If (Tv is veliko) and (qz is veliko) and (BxH is srednje) and (TF is srednje) then (korak_iteracije_3 is nestabilno) (1)
5. If (Tv is veliko) and (qz is veliko) and (BxH is veliko) and (TF is srednje) then (korak_iteracije_3 is asimptotski_stabilno) (1)
6. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is vrlo_veliko) and (TF is veliko) then (korak_iteracije_3 is asimptotski_stabilno) (1)
7. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is vrlo_veliko) and (TF is vrlo_veliko) then (korak_iteracije_3 is asimptotski_stabilno) (1)
8. If (Tv is srednje) and (qz is srednje) and (BxH is veliko) and (TF is srednje) then (korak_iteracije_3 is asimptotski_stabilno) (1)
9. If (Tv is malo) and (qz is malo) and (BxH is malo) and (TF is srednje) then (korak_iteracije_3 is asimptotski_stabilno) (1)
10. If (Tv is veliko) and (qz is vrlo_veliko) and (BxH is vrlo_veliko) and (TF is vrlo_veliko) then (korak_iteracije_3 is asimptotski_stabilno) (1)
11. If (Tv is srednje) and (qz is vrlo_veliko) and (BxH is malo) and (TF is veliko) then (korak_iteracije_3 is nestabilno) (1)
12. If (Tv is veliko) and (qz is vrlo_veliko) and (BxH is malo) and (TF is vrlo_veliko) then (korak_iteracije_3 is nestabilno) (1)
13. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is srednje) and (TF is vrlo_veliko) then (korak_iteracije_3 is nestabilno) (1)

```


Slika 5.38. Definirana neizrazita pravila ponašanja u koraku iteracije 3

Korakom iteracije 3 omogućili ismo rad sustava pri srednjim rasponima vanjskih temperatura i protoka zraka uz srednju geometriju klima komore.

6. Zapis neizrazitih pravila ponašanja

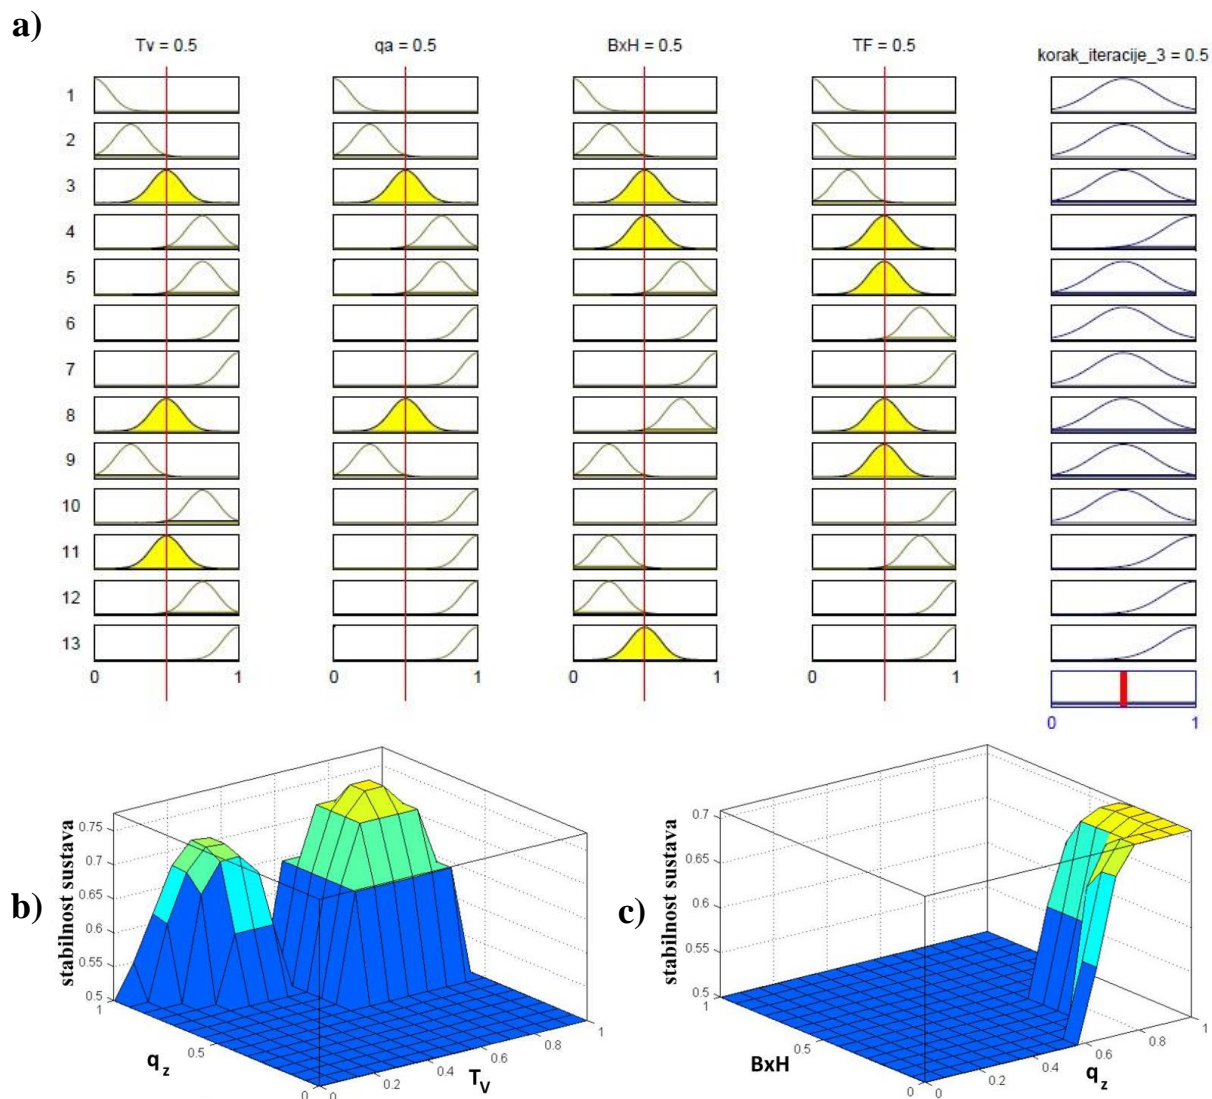
Neizrazita pravila ponašanja sustava zapisati će se u računalnom programu *MATLAB Fuzzy Logic Toolbox* u obliku *fis* datoteke [139].

5.2.8. Dobiveni rezultati nakon koraka iteracije 3



Slika 5.39. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 3); a) matrica komponenata DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.39. daje nam prikaz rezultata dobivenih u koraku iteracije 3. Kao i prije na a) prikazan je rezultat matričnog prikaza arhitekture sustava dobiven matricom komponenata DSM, dok je na slikama b) dan prikaz odziva izlaznih varijabli dobiven MPC metodom, a pod c) prikaz odziva varijabli kod ispitivanja stabilnosti sustava. Na slici 5.39. b i c prikazani su slučajevi odziva izlaznih varijabli sustava kad se promatrani sustav ponaša asimptotski stabilno.



Slika 5.40. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 3); a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable T_V i q_z , c) rezultati globalnog zaključivanja za ulazne varijable q_z i BxH

Analogno, kao i u prethodna dva koraka i ovdje je dan prikaz rezultata, dobiven zaključivanjem na bazi neizrazite logike (prikazano na slici 5.40.). Slika 5.40. b prikazuje nam da je moguć asimtotski rad sustava i pri malim vanjskim temperaturama zraka uz velike raspone protoka zraka. Slika 5.40. c nam kao i u koraku iteracije 2 prikazuje da se asimtotsko ponašanje sustava može postići kod vrlo malih, malih i srednjih geometrija klima komore uz srednje, velike i vrlo velike raspone protoka zraka.

5.2.9. Tablični prikaz rezultata nakon koraka iteracije 3

Tablica 5.7. daje tablični prikaz rezultata na kraju koraka iteracije 3 za pojedine operacije algoritma. Prema neizrazitim pravilima ponašanja može se uočiti da se sustav ponaša nestabilno najveći utjecaj na stabilnost sustava ima vanjska temperatura T_V , u rasponu od -35 – -25 °C, zbog vrlo velikog koeficijenta prijelaza topline α . Isto tako veliki utjecaj na stabilnost imaju i veliki protoci zraka koji nastrujavaju na male poprečne presjeke kanala klima komore. No u većini slučajeva, sustav se ponaša stabilno.

Tablica 5.17. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 3

Arhitektura sustava	Podsustavi: rekuperator topline, grijač zraka, ovlaživač zraka, hladnjak zraka, dogrijač zraka, tlačni vod, odsisni vod, recirkulacijski vod, tlačni ventilator, odsisni ventilator
Matematički model ponašanja sustava	Sustav običnih linearnih diferencijalnih jednačbi (prikaz u prostoru stanja)
MPC metoda	Moguće je postići kvalitetnu simulaciju ponašanja sustava, osim u nestabilnom području
Ispitivanje stabilnosti sustava	Sustav pokazuje nestabilno ponašanje u slučajevima velikih vanjskih temperatura T_V i velikih protoka zraka q_z kad zrak nastrujava na male poprečne presjeke kanala $B \times H$, no može se reći da sustav radi stabilno za većinu kombinacija utjecajnih varijabli

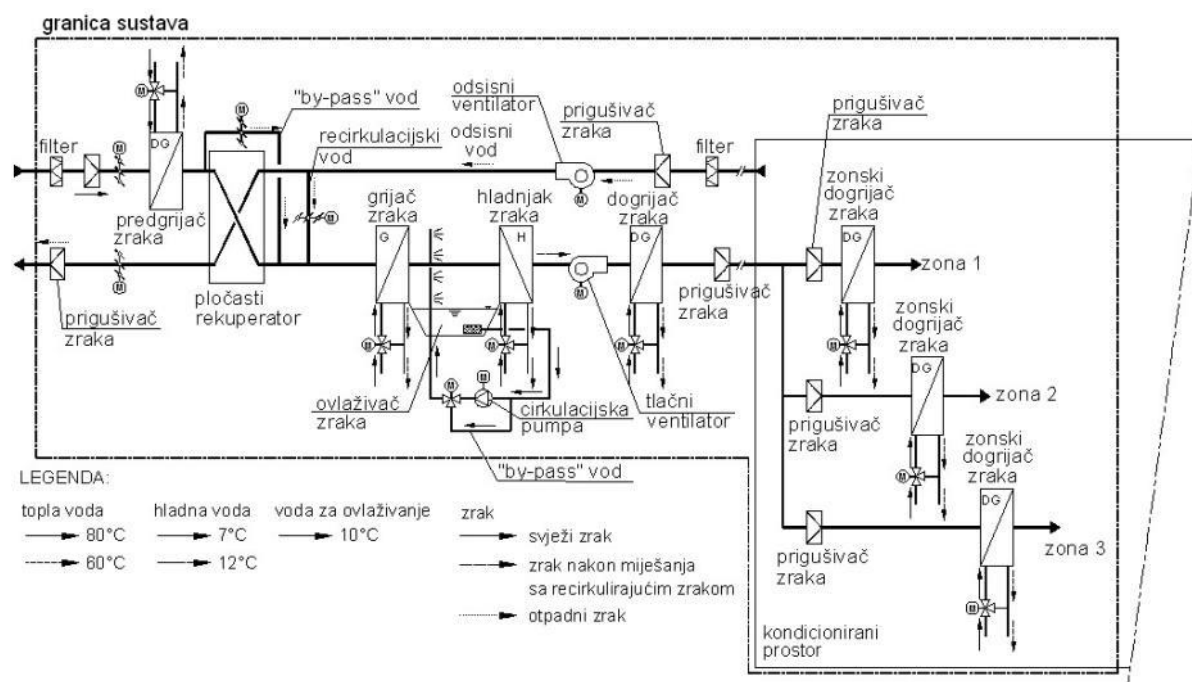
5.2.10. Korak iteracije 4

U četvrtom koraku iteracije (prikazano na slici 5.41.), željeli smo promijeniti prethodnu arhitekturu sustava (opisanu u koraku iteracije 3), dodajući neka nova pravila ponašanja. Za tu svrhu predviđen je podsustav predgrijača zraka, kojim se povisuje vanjska temperatura, prije dovođenja zraka u podsustav rekuperatora topline. Time želimo još više postići stabilnost sustava, a i smanjiti kapacitet rekuperatora topline. Uz to su dodani i podsustavi pripreme zraka za tri zone u poslovnom objektu. Za svaku zonu predviđeni su zonski dogrijači zraka, čime se može ostvariti željena temperatura ubacivanja za svaku od pojedinih zona pripreme zraka.

1. Opisivanje arhitekture sustava

Slika 5.41. prikazuje arhitekturu sustava klima komore nakon dodavanja novih pravila ponašanja, pripreme zraka za različite zone (zone 1, 2 i 3). Matricom komponenata DSM je opisana arhitektura sustava (prikazano na slici 5.43. a), te su dobiveni mogući podsustavi.

U tu svrhu korišten je računalni program *LOOME* [128].



Slika 5.41. Arhitektura sustava klima komore nakon dodavanja novih pravila ponašanja (korak iteracije 4)

2. Kreiranje matematičkog modela ponašanja sustava

Nakon toga kreiran je matematički model ponašanja cjelokupnog sustava u prostoru stanja. Predgrijač zraka, kao i pojedini zonski dogrijači zraka imaju iste matematičke modele, kao što je i kod grijača zraka, odnosno dogrijača zraka (izvedeni su u prethodnim koracima iteracije). Ovdje ih se neće posebno razmatrati.

3. Simuliranje sustava korištenjem MPC metode

Na temelju kreiranog matematičkog modela u prostoru stanja (u računalnom programu MATLAB [137]), simulira se prediktivno upravljanje MPC metodom korištenjem potprograma *MPC Design Tool* unutar programa *MATLAB Model Predictive Toolbox* [138]. U MPC metodi koriste se iste utjecajne varijable koje su prikazane u tablici 5.5. Nakon što se odsimulira MPC metoda, dobiju se odzivi izlaznih varijabli sustava, prikazani na slici 5.43. b. pod točkom 5.2.11.

4. Ispitivanje stabilnosti sustava

Na analogan način kao i u prethodnom koraku iteracije, za matematički model sustava (u prostoru stanja), simulira se ispitivanje stabilnosti izravnom metodom Ljapunova.

Model je kreiran u računalnom programu *MATLAB* [137]. Pritom se koriste iste utjecajne varijable (kao i u prethodnom koraku algoritma 3), koje su prikazane u tablici 5.16. Rezultat ispitivanja stabilnosti sustava prikazan je na slici 5.43. c.

5. Kreiranje neizrazitih pravila ponašanja i njihov grafički prikaz

Kao i u prethodnom koraku iteracije, na osnovu podataka dobivenih MPC metodom, te ispitivanja stabilnosti sustava, uz podatke iz matematičkog modela sustava, kreira se Mamdani model neizrazite logike. U tu svrhu koristi se sustav za odlučivanje u računalnom programu *MATLAB Fuzzy Logic Toolbox* [139]. Semantika utjecajnih varijabli, prikazana je u tablici 5.6. Slika 5.20. prikazuje definirana neizrazita pravila ponašanja u koraku iteracije 3.

Rezultati lokalnog i globalnog zaključivanja prikazani su u dobivenim rezultatima na slici 5.44. Dobiveni rezultati bit će još prokomentirani pod točkom 5.2.11.

1. If (Tv is vrlo_malo) and (qz is vrlo_malo) and (BxH is vrlo_malo) and (TF is vrlo_malo) then (korak_iteracije_4 is globalno_stabilno) (1)
2. If (Tv is malo) and (qz is malo) and (BxH is malo) and (TF is malo) then (korak_iteracije_4 is globalno_stabilno) (1)
3. If (Tv is srednje) and (qz is srednje) and (BxH is srednje) and (TF is srednje) then (korak_iteracije_4 is asimptotski_stabilno) (1)
4. If (Tv is veliko) and (qz is veliko) and (BxH is srednje) and (TF is srednje) then (korak_iteracije_4 is asimptotski_stabilno) (1)
5. If (Tv is veliko) and (qz is veliko) and (BxH is veliko) and (TF is veliko) then (korak_iteracije_4 is asimptotski_stabilno) (1)
6. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is vrlo_veliko) and (TF is veliko) then (korak_iteracije_4 is asimptotski_stabilno) (1)
7. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is vrlo_veliko) and (TF is vrlo_veliko) then (korak_iteracije_4 is nestabilno) (1)
8. If (Tv is srednje) and (qz is srednje) and (BxH is veliko) and (TF is veliko) then (korak_iteracije_4 is asimptotski_stabilno) (1)
9. If (Tv is malo) and (qz is malo) and (BxH is malo) and (TF is srednje) then (korak_iteracije_4 is asimptotski_stabilno) (1)
10. If (Tv is veliko) and (qz is veliko) and (BxH is vrlo_veliko) and (TF is veliko) then (korak_iteracije_4 is nestabilno) (1)
11. If (Tv is srednje) and (qz is srednje) and (BxH is srednje) and (TF is veliko) then (korak_iteracije_4 is asimptotski_stabilno) (1)
12. If (Tv is srednje) and (qz is srednje) and (BxH is vrlo_veliko) and (TF is veliko) then (korak_iteracije_4 is asimptotski_stabilno) (1)
13. If (Tv is srednje) and (qz is srednje) and (BxH is vrlo_malo) and (TF is srednje) then (korak_iteracije_4 is asimptotski_stabilno) (1)
14. If (Tv is veliko) and (qz is veliko) and (BxH is malo) and (TF is srednje) then (korak_iteracije_4 is nestabilno) (1)
15. If (Tv is veliko) and (qz is veliko) and (BxH is vrlo_malo) and (TF is malo) then (korak_iteracije_4 is nestabilno) (1)
16. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is vrlo_malo) and (TF is srednje) then (korak_iteracije_4 is nestabilno) (1)
17. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is malo) and (TF is vrlo_veliko) then (korak_iteracije_4 is nestabilno) (1)
18. If (Tv is vrlo_veliko) and (qz is vrlo_veliko) and (BxH is malo) and (TF is vrlo_veliko) then (korak_iteracije_4 is nestabilno) (1)


Slika 5.42. Definirana neizrazita pravila ponašanja u koraku iteracije 4

Dodavanjem novih pravila ponašanja u sustavu klima komore postigli smo u odnosu na sve prethodne korake iteracije (1–3), globalno stabilno ponašanje sustava u slučajevima malih i vrlo malih raspona protoka zraka, pri vrlo malim i malim rasponima vanjskih temperatura zraka.

6. Zapis neizrazitih pravila ponašanja


Neizrazita pravila ponašanja sustava zapisati će se u računalnom programu *MATLAB Fuzzy Logic Toolbox* u obliku *fis* datoteke [139].

5.2.11. Dobiveni rezultati nakon koraka iteracije 4



Slika 5.43. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 4); a) matrica komponenta DSM, b) MPC metoda – odzivi izlaznih varijabli, c) ispitivanje stabilnosti izravnom metodom Ljapunova

Slika 5.43. prikazuje rezultate dobivene u koraku iteracije 4. Na a) slici prikazan je rezultat matricnog prikaza arhitekture sustava dobiven matricom komponenta DSM, dok je na slikama b) dan prikaz odziva izlaznih varijabli dobiven MPC metodom, a pod c) prikaz odziva varijabli kod ispitivanja stabilnosti sustava. Na slici 5.43. b i c prikazani su slučajevi odziva izlaznih varijabli sustava kad se promatrani sustav ponaša asimptotski stabilno.



Slika 5.44. Dobiveni rezultati za arhitekturu sustava klima komore u zimskom razdoblju (korak iteracije 4); a) rezultati lokalnog zaključivanja, b) rezultati globalnog zaključivanja za ulazne varijable T_v i q_z , c) rezultati globalnog zaključivanja za ulazne varijable q_z i $B \times H$

Za posljednji korak, kao i za prethodna tri, dajemo prikaz rezultata, dobiven zaključivanjem na bazi neizrazite logike (prikazano na slici 5.44.).

Na a) slici prikazan je skup svih raspodjela funkcija pripadnosti za unesena neizrazita pravila u sustav odlučivanja (lokalno zaključivanje), dok slike b) i c) daju prikaz globalnog zaključivanja za dva skupa odabranih ulaznih varijabli (iste kao i u prethodnom koraku), vanjske temperature i protoka zraka, T_v i q_z , te protoka zraka i geometrije klima komore, q_z i $B \times H$.

5.2.12. Tablični prikaz rezultata nakon koraka iteracije 4

Tablica 5.8. daje tablični prikaz rezultata na kraju koraka iteracije 4 za pojedine operacije algoritma. Prema neizrazitim pravilima ponašanja može se uočiti da se sustav ponaša nestabilno najveći utjecaj na stabilnost sustava ima vanjska temperatura T_V , u rasponu od -35 – -25 °C, zbog vrlo velikog koeficijenta prijelaza topline α . Isto tako veliki utjecaj na stabilnost imaju i veliki protoci zraka koji nastrujavaju na male poprečne presjeke kanala klima komore. No u većini slučajeva, kao i u prethodnom slučaju, sustav se ponaša stabilno.

Tablica 5.18. Prikaz dobivenih rezultata u pojedinim operacijama algoritma nakon koraka iteracije 4

Arhitektura sustava	Podsustavi: rekuperator topline, grijač zraka, ovlaživač zraka, hladnjak zraka, dogrijač zraka, zonski dogrijač zraka 1, zonski dogrijač zraka 2, zonski dogrijač zraka 3, tlačni vod, odsisni vod, recirkulacijski vod, tlačni ventilator, odsisni ventilator
Matematički model ponašanja sustava	Sustav običnih linearnih diferencijalnih jednadžbi (prikaz u prostoru stanja)
MPC metoda	Moguće je postići kvalitetnu simulaciju ponašanja sustava, osim u nestabilnom području
Ispitivanje stabilnosti sustava	Sustav pokazuje nestabilno ponašanje u slučajevima velikih vanjskih temperatura T_V i velikih protoka zraka q_z kad zrak nastrujava na male poprečne presjeke kanala $B \times H$, no može se reći da sustav radi stabilno za većinu kombinacija utjecajnih varijabli, kao i u koraku iteracije 3

5.3. Implikacije na rad

U ovom poglavlju provedena je verifikacija pristupa. Kao realni primjeri složenih tehničkih sustava, odabrani su elektromehanički sustav (uređaj za dizanje tereta) i toplinsko – hidraulični sustav (klima komora). Oba tehnička sustava mogu se uz određene pretpostavke i promjene matematičkog modela ponašanja promatrati kao linearni sustavi.

Dok je uređaj za dizanje primjer izrazito nelinearnog sustava i to vrlo brzog sustava s malim vremenskim konstantama, dotim je klima komora primjer izrazito linearnog sustava s vrlo velikim vremenima kašnjenja. Primjeri su odabrani s namjerom da se pokaže da je predloženi algoritam primjenjiv za različite vrste složenih tehničkih sustava s obzirom na njihov tip ponašanja. Algoritmom je pokazano da se kroz nekoliko iterativnih koraka, može na učinkovit i brz način razviti arhitektura novog, kao i poboljšati već postojeća arhitektura složenog tehničkog sustava.

U prvom primjeru smo mijenjali arhitekturu prijenosnika snage u 2 i 3 koraku iteracije s namjerom da omogućimo rad sustava pri većim prijenosnim omjerima i većim brzinama spuštanja/ dizanja tereta u stabilnijem režimu rada sustava kod većih brzina vjetra. Kod drugog primjera smo dodavanjem podsustava u koracima iteracije 2 i 3, utjecali na to da smanjimo utjecaj niskih vanjskih temperatura T_V na stabilnost sustava. Također kao i u prvom primjeru u posljednjem koraku iteracije smo pokazali da je moguće dodavati i neka nova pravila ponašanja.

Na osnovu predložene arhitekture sustava, te kroz ispitivanje ponašanja koristeći MPC metodu i Ljapunovljevu metodu stabilnosti, može se predvidjeti kako bi se dotični složeni tehnički sustav ponašao u realnim radnim uvjetima, izložen pritom neizvjesnim uvjetima okoline. Kažemo da se preko analize ponašanja sustava mogu donijeti zaključci kako utjecati na promjenu same arhitekture složenog tehničkog sustava.

Velika prednost algoritma je i omogućavanje zapisa ponašanja složenog tehničkog sustava i to pomoću neizrazitih pravila, za njegovu određenu varijantu. Dobivena varijanta složenog tehničkog sustava se može mijenjati, tj. nadopunjuje ju se novim pravilima ponašanja.

RASPRAVA

Poglavlje pruža usporedbu postavljenih ciljeva s dobivenim rezultatima primjene algoritma na realnim primjerima složenih tehničkih sustava (prikazanim u prethodnom poglavlju), te s trenutnim stanjem tehnike. Za usporedbu sa trenutnim stanjem tehnike predloženi algoritam razvoja arhitektura složenih tehničkih sustava, uspoređen je s poznatim okruženjem iz znanstvene literature. Uz to utvrđuje se koja je mogućnost primjene algoritma razvoja arhitektura složenih tehničkih sustava u realnom okruženju.

6.1. Usporedba postavljenih ciljeva istraživanja s dobivenim rezultatima, te trenutnim stanjem tehnike

Na početku prikazanog istraživanja u doktorskom radu kao cilj istraživanja je postavljen razvoj algoritma razvoja arhitektura složenih tehničkih sustava. Prikazani algoritam će omogućiti modeliranje i predviđanje ponašanja tehničkog sustava u radnoj okolini, pri radnim i neizvjesnim uvjetima rada. Algoritam je temeljen na prikazu dinamičkog ponašanja sustava i njegovog zapisa pravilima. Prikazani algoritam će pomoći kako u razvoju novih, tako i u poboljšanju postojećih arhitektura složenih sustava, preslikavanjem u oba smjera, iz strukturne u ponašajnu domenu i obrnuto.

Odabirom pojedinih metoda (za svaku operaciju u algoritmu), prema prikazanoj metodologiji istraživanja, prikazan je algoritam sa opisom pojedinih matematičkih modela.

Ukratko prijenos informacija između pojedinih operacija algoritma, može se opisati kako slijedi u nastavku. Na početku se na osnovu predloženih zahtjeva kupaca, te iz njih kreiranih inženjerskih zahtjeva, korištenjem katalogskih podataka proizvođača za slične sustave predlaže početna (inicijalna) arhitektura sustava. Matricom komponenata DSM opisuje se arhitektura predloženog složenog tehničkog sustava. DSM nam daje informaciju o mogućim podsustavima (modulima). Na osnovu tih informacija o mogućim podsustavima se prema uvedenim pretpostavkama za matematičko modeliranje postavljaju jednačbe za pojedine procese u sustavu. U slučaju složenog sustava, sustav se dekomponira na elementarne procese, koji se onda svaki zasebno modelira svaki proces. Tako dobiveni matematički modeli se nakon toga zapisuju u prostoru stanja. Matematički model sustava daje nam i mogućnost matematičkog opisivanja neizvjesnosti uslijed vanjskih uvjeta, kojima je promatrani tehnički sustav izložen. MPC metoda provodi simulaciju ponašanja na osnovu tog matematičkog modela. Uz odabir svih prije navedenih parametara, potrebnih za provođenje simulacije, promatra se da li je moguće ostvariti kvalitetnu simulaciju tehničkim sustavom. Tu razlikujemo dva glavna slučaja. Prvi je kad imamo linearni sustav, kod kojega se stabilnost ispituje na osnovu matematičkog modela sustava, tj. koristi se njegova matrica A . U drugom slučaju kod nelinearnog sustava, koji se ne može svesti na linearni oblik, a da se ne izgube neka od njegovih svojstava dinamičkog ponašanja, potrebno je kod ispitivanja stabilnosti sustava uzeti u obzir zajedno matematički model ponašanja sustava i kriterijsku funkciju MPC metode. Utjecajne varijable koje bi trebalo uzeti u obzir kod definiranja neizrazitih pravila ponašanja (kao ulazne varijable) iz matematičkog modela ponašanja sustava, određuje konstruktor na osnovu svog iskustva. To vrijedi u oba slučaja (i kod linearnih i kod nelinearnih sustava). Informacija dobivena ispitivanjem stabilnosti sustava (tj. da li je nestabilan, asimptotski stabilan ili globalno stabilan) se kasnije koristi kao izlazna varijabla kod kreiranja neizrazitih pravila ponašanja u sustavu odlučivanja. Za određeni sustav za kojeg se kroz prethodne korake ustanovi da ima zadovoljavajuće ponašanje (stabilan rad sustava za većinu ulaznih varijabli), te stabilan rad sustava kod neizvjesnih radnih uvjeta, može se predložiti za novo razvijenu varijantu tehničkog sustava ili novo poboljšanu varijantu nekog postojećeg tehničkog sustava. U slučaju da sustav nema zadovoljavajuće ponašanje, te je nestabilan u neizvjesnim uvjetima rada, ponavlja se cijeli postupak algoritma putem povratnih petlji. Kažemo da se radi o iterativnom postupku određivanja neizrazitih pravila ponašanja. U pravilu je potrebno više koraka iteracije da bismo došli do zadovoljavajućeg rješenja.

Verifikacija algoritma je provedena na razvoju arhitektura dva realna složena tehnička sustava (uređaja za dizanje tereta i klima komore).

Oba odabrana tehnička sustava su različita po kriteriju tipa njihovog ponašanja. Uređaj za dizanje tereta, je primjer izrazito nelinearnog sustava sa brzim promjenama, odnosno, malim vremenskim konstantama. S druge pak strane klima komora je primjer tipično linearnog sustava sa velikih vremenima kašnjenja. Kroz nekoliko koraka iteracije za svaku pojedinu operaciju algoritma pokazano je da se uz uključivanje/uklanjanje novih podsustava, može utjecati na promjenu ponašanja sustava, tokom razvoja njihovih arhitektura. Također algoritam nam omogućava zapis ponašanja sustava za pojedinu varijantu sustava. Moguć je razvoj novih arhitektura složenih tehničkih sustava, kao i poboljšanje postojećih. Matematičko modeliranje omogućuje izradu matematičkih modela ponašanja promatranih sustava, odnosno podsustava ili samih pojedinačnih procesa. Uz to ono nam omogućava uključivanje u model poremećajnih varijabli, koje uzrokuju neizvjesne uvjete rada. Predviđanje ponašanja putem MPC metode omogućava nam da razvijamo arhitekture sustava na osnovu već poznatog ponašanja sličnih sustava, te provjeravamo da li je moguće podesiti parametre da bi se kvalitetno simulirao sustav tokom njegovom rada u realnim radnim, kao i pod djelovanjem neizvjesnih uvjeta rada. Ispitivanje stabilnosti sustava opet daje ocjenu da li je sustav da svojim podsustavima radi u stabilnom području rada.

Iz dobivenih rezultata istraživanja, uz provedenu raspravu u ovom poglavlju, te uz osvrt na ograničenja koja su se javila tijekom istraživanja, došlo se do zaključaka koji su opisani u sljedećem poglavlju pod točkom 7.3.

6.1.1. Primjer 1 – elektromehanički sustav – uređaj za dizanje tereta

Kod prvog primjera sustava uređaja za dizanje, verifikacija je provedena kod velikih brzina vjetra, tj. neizvjesnih radnih uvjeta. U takvim uvjetima razvijali smo arhitekturu tehničkog sustava uz ispitivanje njegovog ponašanja (kvalitete simuliranja ponašanja i stabilnosti sustava).

Tehnički sustav je izrazito nelinearnog karaktera, koji se jednim od postupaka linearizacije (tangentna linearizacija), te uz uvođenje dodatnih pretpostavki lineariziran i kao takav promatran tokom prikazanog istraživanja u koraku verifikacije.

Provedenim ispitivanjem (pregledom neizrazitih pravila, te rezultata lokalnog i globalnog zaključivanja, u svakom koraku iteracije), uočava se nekoliko zaključaka (vidi prethodno poglavlje):

- Najveći utjecaj na stabilnost sustava ima velika brzina vjetra v_V , u rasponu od nekih 22.2 – 27.8 m/s, kod malih brzina vrtnje elektromotora;
- Drugi veliki utjecaj na stabilnost sustava imaju male brzine vrtnje elektromotora, kod velikih prijenosnih omjera u prijenosniku snage;
- U sustavu odlučivanja uveden težinski faktor TF, koji se kreće u rasponu od 0 do 1. Faktor nema nikakav utjecaj na samu stabilnost tehničkog sustava, pošto se MPC metoda kod linearnih sustava uvijek ponaša asimptotski stabilno. Navedeni faktor ima samo utjecaj na kvalitetu simuliranja ponašanja tehničkog sustava.

U koraku iteracije 2 dodavanjem novih komponenata u podsustavu prijenosnika snage, smanjen je prijenosni omjer po pojedinom stupnju prijenosa. Tu je ispitivanje provedeno s dvostupanjskim prijenosnikom, dok je u koraku 3 promijenjena vrsta prijenosnika (planetarni prijenosnik). Time je opet postignuto da se dobije sustav koji će moći raditi s velikim prijenosnim omjerima. Kao i kod prvog primjera i ovdje je pokazano da je moguće primijeniti algoritam uvođenjem novih pravila ponašanja sa zadovoljavajućim rezultatima ispitivanja. Dodan je još jedan sustav sa potpuno istim podsustavima, kao što je onaj u koraku 3 iteracije. Time se želi ostvariti mogućnost istovremenog dizanja/spuštanja većih tereta. Pritom oba sustava rade ujednačeno (s istim brzinama elektromotora, te s istim brzinama dizanja i spuštanja tereta). Uz to smo omogućili rad sustav pri većim brzinama dizanja i pri velikim brzinama vjetra.

Mijenjanjem podsustava prijenosnika snage postiglo se kroz nekoliko koraka iteracije da uređaj može raditi u neizvjesnim radnim uvjetima, kod jakih brzina vjetra. Verifikacija je na ovom primjeru pokazala da se povezivanjem modela strukture i modela ponašanja kroz nekoliko iterativnih koraka, moguće razviti arhitekturu složenog tehničkog sustava, predviđanjem njegovog ponašanja, ispitivanjem kvalitete simulacije ponašanja, kao i ispitivanjem njegove stabilnosti.

6.1.2. Primjer 2 – toplinsko–hidraulični sustav – klima komora

U drugom primjeru tehničkog sustava klima komore, verifikacija se provodila samo za razdoblje rada u zimskom razdoblju, jer jedino tada ima smisla proučavati utjecaj neizvjesnih radnih uvjeta. Neizvjesni uvjeti rada javljaju se uslijed niskih vanjskih temperatura koje najviše utječu na samu stabilnost tehničkog sustava. Sustav je izrazito linearan i kao takav je promatran tokom prikazanog istraživanja. Moguće ga je matematički opisati skupom običnih diferencijalnih jednadžbi bez prethodnog postupka linearizacije.

Također, budući da je klima komora, kao toplinsko - hidraulični sustav, pretežito kontinuiranog karaktera, ispitivani su njeni podsustavi u kontinuiranoj domeni.

Diskretne domene (elektromotori ventilatora, motori troputnih ventila, te motori zaklopki), ovdje nisu bili predmetom istraživanja, jer nemaju značaj utjecaj na rad sustava, pogotovo tokom neizvjesnih uvjeta rada.

Simuliranjem ponašanja tehničkog sustava, kao i ispitivanjem njegove stabilnosti (pregledom neizrazitih pravila, te rezultata lokalnog i globalnog zaključivanja, u svakom koraku iteracije), uočava se nekoliko činjenica (vidi točku 5.4. prethodnog poglavlja):

- Najveći utjecaj na stabilnost sustava ima vanjska temperatura T_V , u rasponu od -35 – -25 °C, zbog vrlo velikog koeficijenta prijelaza topline α , kod tako niske temperature zraka;
- Drugi veliki utjecaj na stabilnost sustava, imaju velike brzine strujanja, odnosno veliki volumni protoci zraka q_z , kod manjih geometrija klima komore (pritom mislimo na površinu poprečnog presjeka komore $B \times H$);
- Kao i u prethodnom primjeru i ovdje je u sustavu odlučivanja uveden težinski faktor TF, koji se kreće u rasponu od 0 do 1, no nema nikakav utjecaj na samu stabilnost tehničkog sustava, pošto se MPC metoda kod linearnih sustava (bez obzira radi li se o vremenski invarijantnim ili varijantnim sustavima), uvijek ponaša asimptotski stabilno. Navedeni faktor pritom ima samo utjecaj na kvalitetu simuliranja rada tehničkog sustava.

Dodavanjem pojedinih podsustava (predgrijač zraka, rekuperator topline, proces miješanja zraka, dogrijač zraka) u klima komori, tijekom pojedinih koraka iteracije, dobivena je puno viša temperatura na ulazu u posljednji podsustav (temperatura prije samog ubacivanja zraka u kondicionirani prostor). Veliku razliku temperature koju smo imali kod jednog podsustava, uvođenjem novih podsustava, smo podijelili na više njih. Uz to time su smanjeni i kapaciteti ostalih podsustava, te je osiguran stabilan rad tehničkog sustava. U koraku iteracije 4 pokazano je da je moguće primijeniti algoritam, uvođenjem novih pravila ponašanja sa zadovoljavajućim rezultatima (kvalitetna simulacija rada, kao i stabilno stanje sustava tokom radnih i neizvjesnih uvjeta). Dodani su zonski dogrijači zraka za zagrijavanje pojedinih zona u poslovnom objektu.

Verifikacija na ovom primjeru je kao i kod prvog primjera pokazala da je povezivanjem modela strukture i modela ponašanja kroz nekoliko iterativnih koraka, moguće razviti arhitekturu složenog tehničkog sustava, predviđanjem njegovog ponašanja, kao i ispitivanjem njegove stabilnosti.

6.1.3. Usporedba s trenutnim stanjem tehnike

Za usporedbu sa trenutnim stanjem tehnike, odabrana je slično okruženje iz znanstvene literature ([4], [6], [7], [20]). S tim okruženjem je napravljena usporedba prikazanog algoritma iz doktorskog rada. *Diepold i ostali* razvili su okruženje sa algoritmom koje se sastoji od tri faze, a služi generičkom povezivanju modela strukture i modela ponašanja sustava, naziva (engl. *The quad-I/HS - Interactive Interaction Importance Identification/Hybrid State framework*). Okruženje je primjenjivo na složene tehničke sustave i za rad pri neizvjesnim radnim uvjetima. U nastavku slijedi kratki opis okruženja. Nakon inicijalizacije sustava i njegovog opisivanja DSM ili MDM metodom, kreće se u prvu fazu okruženja (engl. *Quad - I - Interactive Interaction Importance Identification*). Ona se sastoji od: kvantificiranja parametara, pridruživanje koeficijenata značajnosti pojedinim elementima u metodama DSM ili MDM, redukcija reda, određivanja koeficijenata modeliranja, preslikavanja koeficijenata značajnosti u koeficijente modeliranja, te procjene trenutne granice greške, kao i kvalitete rezultata matričnog prikaza. Na kraju faze ispituje se odluka da li zadnji korak u fazi zadovoljava ili ne. U slučaju da ne zadovoljava, postoji povratna veza na poboljšanje podataka, te ako je to moguće ide se u ponavljanje procjene trenutne granice greške, kao i kvalitete rezultata matričnog prikaza.

Ako nije moguće poboljšanje podataka vraća se na početak prve faze gdje se radi poboljšanje podsustava definiranih u DSM i MDM metodi. U suprotnom slučaju ako odluka na kraju prve faze zadovoljava, kreće se u drugu fazu (engl. *GHSM – Generalized Hybrid State Model*), koja preslikava i modelira strukturu sustava u hibridni dinamički prikaz. Sastoji se od slijedećih faza: deklaracije dinamičke DSM metode (engl. *Dyn-DSM*), fragmentacije domene ponašanja, modeliranja kontinuirane i diskretne domene, sa redukcijom reda modela, te modeliranja preslikavanja domene.

Nakon toga opet se ispituje uvjet da li preslikavanje u hibridni model zadovoljava, te ako ne zadovoljava radi se promjena u podacima i ponovo vraća povratnom petljom informacija u prvu fazu, gdje se opet procjenjuje trenutna granica greške, kao i kvaliteta matričnog prikaza.

Postupak se opet ponavlja kroz drugu fazu sve dok odluka nije pozitivna, nakon čega se može reći da je dobiven model u GHSM prikazu. U suprotnom slučaju ponavlja se isti proces kao i na kraju prve faze kada odluka nije zadovoljavajuća. Treća faza u okruženju je faza poboljšanja. Prikaz tehničkog sustava u navedenom okruženju, dan je za stacionarno stanje.

Algoritam razvoja arhitektura složenih tehničkih sustava definiran i verificiran u ovom doktorskom radu, bazira se na nekim nedostacima navedenog okruženja i njegovog algoritma (vidi točku 6.1. ovog poglavlja), koji su:

- Mogućnost kreiranja matematičkog modela ponašanja pojedinih procesa (u nestacionarnom stanju, tj. prikaza promjene promatrane varijable tokom vremena), odnosno podsustava u promatranom tehničkom sustavu;
- Prikaz modela ponašanja tehničkog sustava u nelinearnom obliku, s mogućnošću prevođenja u linearnom obliku, osim u slučajevima kada je promatrani sustav izrazito nelinearan, i mora se promatrati u tom obliku;
- Mogućnost poboljšanja ponašanja tehničkog sustava, direktno kroz domenu ponašanja, promjenom parametara u matematičkom modelu ponašanja tehničkog sustava, te podešavanjem parametara u MPC metodi;
- Mogućnost razvoja poboljšanih arhitektura tehničkih sustava na osnovu sličnog modela ponašanja, koristeći MPC metodu, gdje se simulira ponašanje prema već nekoj poznatoj trajektoriji promjene stanja promatrane varijable sustava;
- Mogućnost ispitivanja stabilnosti pojedinih procesa i podsustava ispitivanog tehničkog sustava;

- Zapis ponašanja tehničkog sustava, odnosno pojedinih varijanti tehničkog sustava pomoću kreiranja neizrazitih pravila ponašanja. Dotična pravila ponašanja, imaju mogućnost mijenjanja, odnosno dopunjavanja. Time kreiramo nove varijante sustava ili mijenjamo već neke postojeće;
- Algoritam je primjenjiv na složene tehničke sustave, dok je opisano okruženje testirano na jednostavnom primjeru kemijske olovke.

Ono što još za sad nije napravljeno u prikazanom algoritmu u ovom radu, je da nema automatskog prijenosa informacija između pojedinih operacija, tj. iz domene strukture u domen ponašanja i obrnuto. To se može predvidjeti kao jedan od mogućih smjerova budućih istraživanja.

6.2. Utvrđivanje mogućnosti primjene algoritma razvoja arhitektura složenih tehničkih sustava u realnom okruženju

Prikazani algoritam razvoja arhitektura složenih tehničkih sustava, primjenjiv je za široki raspon složenih tehničkih sustava u realnom okruženju. U doktorskom radu je prikazana verifikacija na dva različita primjera složenih tehničkih sustava po tipu njihovog ponašanja.

No treba reći da je u doktorskom radu provedena samo teoretska analiza ponašanja prikazanih tehničkih sustava. Usprkos dobivenim rezultatima simulacije, osnovni preduvjet da bi se predloženi algoritam potvrdio u realnom okruženju, bilo bi njegovo testiranje, tj. provođenje eksperimenta u realnim radnim uvjetima. No zbog trenutne nemogućnosti provedbe takvog eksperimenta, to nije bio predmet istraživanja u ovom doktorskom radu. No, za takvo što potrebno je imati i prototip ispitivanog proizvoda.

MPC metoda, koja je implementirana u algoritmu, a služi za predviđanje ponašanja tehničkih sustava, prvotno je bila razvijena za sustave u procesnoj industriji. Stoga bi algoritam prvenstveno bio jako dobro primjenjiv za složene tehničke sustave (npr. postrojenja u procesnoj industriji ili one koji se misle upotrebljavati za slične namjene). Kasnijim razvojem algoritama upravljanja, MPC metoda, je postala upotrebljiva i za vrlo brze sustave, kao što su npr. elektromehanički sustavi. Kroz prikazane primjere složenih tehničkih sustava, tokom verifikacije, prikazana je mogućnost primjene algoritma na obje vrste tehničkih sustava.

Algoritam je primjenjiv i na tzv. tip dinamičkih sustava, multivarijabilne (MIMO) sustave, odnosno sustave s više ulaza i izlaza.

MPC metoda, uz to pruža i mogućnost poboljšanja postojećih arhitektura složenih tehničkih sustava, zbog poznavanja referentne trajektorije promjene promatrane veličine tehničkog sustava. Složeni matematički modeli koji stoje iza prikazanog algoritma, zahtijevaju prije svega i veliko iskustvo konstruktora u radu, te uz to zahtijevaju i zahtjeve glede računalne opreme na kojima će se izvršavati prikazani algoritam.

6.3. Implikacije na rad

Poglavlje nam daje raspravu glede dobivenih rezultata u prethodnom poglavlju, te njihovu usporedbu s postavljenim ciljevima, te trenutnim stanjem tehnike. Uz to dan je kratak osvrt na mogućnost primjene algoritma u realnom okruženju. Na osnovu provedene rasprave na temelju usporedbe dobivenih rezultata objasniti će se ograničenja (na koja se naišlo tokom istraživanja), kao i zaključak provedenog istraživanja u sljedećem poglavlju.

ZAKLJUČAK

U posljednjem poglavlju na početku je dan kratak sažetak provedenog istraživanja. Nakon toga su opisana ograničenja s kojima smo se susreli prilikom provedbe samog istraživanja. Na kraju je dan zaključak provedenog istraživanja, te smjerovi mogućih budućih istraživanja.

7.1. Sažetak provedenog istraživanja

Prema korištenoj metodologiji istraživanja u ovom doktorskom radu, koja se temelji na modificiranoj deskriptivnoj DRM metodologiji, prema *Blessing i Chakabarti* [22], cilj istraživanja bio je razviti algoritam za modeliranje i predviđanje ponašanja u radnoj okolini, koji je temeljen na prikazu dinamičkog ponašanja sustava i njegovog zapisa pravilima. Time će se pomoći u razvoju kako novih, tako i u poboljšanju postojećih arhitektura složenih tehničkih sustava, preslikavanjem u oba smjera, iz strukturne u ponašajnu domenu i obrnuto.

U sklopu provedenog istraživanja u ovom radu daju se doprinosi u teorijskom i primijenjenom dijelu. Teorijski doprinos proizlazi iz algoritma temeljenog na procesu preslikavanja iz strukturne u ponašajnu domenu i obrnuto. Primijenjeni dio doprinosa se odnosi na primjenu algoritma na realnim primjerima složenih tehničkih sustava, kojima će se vrednovati rezultati istraživanja. Vrednovanje rezultata istraživanja provedeno je na dva realna primjera složenih tehničkih sustava.

Kao prvi primjer je odabran elektromehanički sustav (uređaj za dizanje tereta), koji se sastoji od elektromotora, prijenosnika snage, te bubnja s kukom. Namjena mu je dizanje/ spuštanje tereta na mosnim granicama u brodogradilištima. Za drugi primjer odabran je toplinsko – hidraulični sustav (klima komora), kakva se često koristi za pripremu zraka u poslovnim objektima (kao što su npr. trgovački centri, kongresni centri, poslovne zgrade itd.).

Algoritam je uspoređen s jednim sličnim algoritmom iz pristupa iz znanstvene literature. Pritom su ukazani nedostaci postojećeg pristupa, na kojima se temelji predloženi algoritam u ovom doktorskom radu.

U nastavku se daje kratki opis istraživanja po koracima navedene metodologije istraživanja.

7.1.1. Obrazloženje

Prvi korak prema predloženoj metodologiji istraživanja je obrazloženje koje je u ovom doktorskom radu obuhvaćeno prvim i drugim poglavljem. Prvo poglavlje izlaže motivaciju koja je istraživača potaknula na ovo istraživanje, te se navodi cilj i svrha istraživanja. Hipotezama rada su postavljeni kriteriji i granice istraživanja uz istraživačka pitanja, metodologiju istraživanja, te očekivani znanstveni doprinos doktorskog rada. Drugo poglavlje izlaže pregled postojeće znanstvene i stručne literature u području domenskog preslikavanja i neizvjesnosti u konstruiranju, te pobliže objašnjava osnovne pojmove: sustav i složeni sustav, arhitektura proizvoda, dinamički sustavi, stabilnost dinamičkih sustava, te odlučivanje u konstruiranju.

7.1.2. Analiza

Druga cjelina obrađuje korak 2 u metodologiji istraživanja, tj. analizu, a obuhvaćena je 3. poglavljem. Uz teoretske osnove kao polazište istraživanja, dan je kratak pregled inženjerstva sustava, te metodologije konstruiranja mehatroničkih proizvoda. Slijedi opis teorije područja, te opis modeliranja dinamičkih sustava. Dan je i kratki pregled metode modelskog prediktivnog upravljanja (MPC), te metoda određivanju stabilnosti dinamičkih sustava prema Ljapunovu. Na kraju poglavlja ukratko su opisani sustavi odlučivanja bazirani na neizravnoj logici.

7.1.3. Sinteza

Sintezom je dan prijedlog algoritma za razvoj arhitektura složenih tehničkih sustava, a obuhvaćen je 4. poglavljem. U tom poglavlju objašnjen je razvoj algoritma uz definiranje pojedinih operacija u njemu. Uz to opisani su i prikazani pojedini matematički modeli vezani uz svaku navedenu operaciju. Najprije je objašnjen princip opisa arhitekture tehničkih sustava pomoću DSM-a. Nastavilo se s opisom i principom kreiranja matematičkog modela ponašanja tehničkih sustava u prostoru stanja. Uz to je opisan i prikazan model MPC metode, te model ispitivanja stabilnosti sustava izravnom metodom Ljapunova. Cjelina završava modelom sustava odlučivanja baziranog na neizrazitoj logici. Svaka pojedina operacija u algoritmu sa svojim koracima prikazana je dijagramom toka.

7.1.4. Verifikacija

Četvrti korak u metodologiji je verifikacija koja sadrži vrednovanje rezultata istraživanja analizom na odabranim primjerima realnih složenih tehničkih sustava. Obuhvaćena je 4. poglavljem, Kao primjeri tehničkih sustava odabrani su: elektromehanički sustav (uređaj za dizanje tereta) i toplinsko – hidraulični sustav (klima komora). Kreirani su pojedini matematički modeli prema prikazanim operacijama algoritma razvoja arhitektura složenih sustava. Verifikacija je provedena kroz nekoliko iterativnih koraka, s prikazom dobivenih rezultata. Na kraju svakog koraka iteracije dan je tablični prikaz rezultata po pojedinim operacijama algoritma.

7.1.5. Rasprava

Rasprava je posljednji korak u metodologiji, a obuhvaćena je 6. i 7. poglavljem. U 6. poglavlju dana je rasprava, gdje se obrađuju postavljeni ciljevi istraživanja, te uspoređuju s dobivenim rezultatima, te postojećim stanjem tehnike. Uz to utvrđuje se mogućnost primjene algoritma u realnom okruženju. Sedmo poglavlje daje nam uz kratki sažetak prikazanog istraživanja i ograničenja koja su se javila tijekom istraživanja, zaključak, te moguće pravce daljeg istraživanja.

7.2. Ograničenja u istraživanju

Glavno ograničenje, tijekom prikazanog istraživanja, bila je prije svega nemogućnost eksperimentalnog pristupa, tokom ispitivanja ponašanja svake od arhitektura sustava u pojedinim koracima iteracije. Stoga je tijekom modeliranja i provedbe simulacija bila moguća samo primjena teoretske analize. Mogućnost eksperimentalnog pristupa omogućio bi dobivanje točnijeg matematičkog modela ponašanja tehničkog sustava. Provođenjem eksperimentalnog pristupa, zaokružila bi se cjelina i napravio snažniji korak implementaciji predloženog algoritma razvoja složenih tehničkih sustava tijekom njegovog rada u realnoj okolini. Zbog toga bi se kao jedan od smjerova budućih istraživanja moglo predložiti istraživanje primjena neke od metoda identifikacije u modeliranju tehničkog sustava.

Drugo ograničenje je usko povezano s prvim, a tiče se nemogućnosti provedbe prikazanog algoritma u razvoju arhitektura nekih izrazito nelinearnih sustava (npr. letjelica ili ronilica), koji se ne mogu linearizirati, a da se ne izgubi dio njihovog ponašanja u realnim uvjetima rada. Za njegovu provedbu bi bilo nužno provesti eksperimentalno ispitivanje u realnim uvjetima (zbog procjene stanja sustava), uz kreiranje prototipa proizvoda. Zbog trenutnih nemogućnosti da se provede, to je ostavljeno kao jedan od mogućih smjerova budućeg istraživanja (koji su navedeni u točki 7.4. ovog poglavlja).

Treće ograničenje je dugotrajnost postupka simuliranja ponašanja i ispitivanja stabilnosti sustava. U svakom koraku iteracije potrebno je varirati određeni broj varijabli, stavljajući ih u odnose jednu s drugom. Takav način bi se mogao ubrzati proširenjem sustava odlučivanja, tj. omogućavanjem automatskog kreiranja funkcija pripadnosti uvođenjem tzv. neuro–izrazitog sustava odlučivanja (engl. *Neuro – Fuzzy Inference System*).

Posljednje ograničenje je nemogućnost analize i sinteze tehničkog sustava na nivou komponenata (elemenata) sustava. U ovom radu sve smo promatrali na nivou podsustava (modula). Drugim riječima to bi značilo da nakon provedenog odlučivanja i zapisa ponašanja sustava, ne postoji mogućnost ukazivanja na kritičnu/e komponentu/e podsustava. Pritom se misli na komponentu/e podsustava koju (e) bi trebalo ukloniti ili uključiti u arhitekturu podsustava. Time bi se dobilo zadovoljavajući rezultati pri ispitivanju ponašanja složenog tehničkog sustava. Ovaj nedostatak je također predložen kao jedan od mogućih budućih smjerova istraživanja.

7.3. Zaključak provedenog istraživanja

Algoritam se pokazao kao vrlo dobra mogućnost da se u budućnosti razvije kao učinkovit i brz alat, kao pomoć konstruktorima. Koristio bi se kako u razvoju novih, tako i u poboljšanju postojećih arhitektura sustava u ranim fazama procesa konstruiranja. Obostrano preslikavanje podataka između modela strukture i modela ponašanja složenih tehničkih sustava, omogućava zapis ponašanja sustava tijekom normalnog radnih uvjeta, kao i rada u neizvjesnim situacijama.

Vrednovanjem rezultata ispitivanja pri razvoju tehničkih sustava, algoritam se pokazao jako dobrim za sustave s vremenski jako sporim procesima, tj. procesima s vremenskim kašnjenjem (kao što su npr. procesi u termotehnici i procesnoj tehnici). Također je pokazao svoju uporabljivost i za sustave s brzim procesima, kao što su elektromotorni sustavi. Vrednovanje je provedeno na dva realna primjera složenih tehničkih sustava (uređaja za dizanje tereta i klima komore).

Kao prvi primjer u verifikaciji je odabrana odabran je elektromehanički sustav, kakav se koristi za dizanje tereta na granicama u brodogradilištima.

Variranjem odabranih utjecajnih parametara, dijelom dobivenih iz matematičkog modela kao što su: brzina vrtnje elektromotora, prijenosni omjer u prijenosniku snage, masa tereta i brzina vjetra. Također je odabran i parametar iz MPC metode tj. težinski faktor. Pomoću njih ispitivalo se ponašanje tehničkog sustava. U tu svrhu korištena je MPC metoda, te je ispitivana stabilnost navedenog sustava. Na osnovu dobivenih podataka kreirala su se neizrazita pravila ponašanja sustava, koristeći odlučivanje bazirano na Mamdami modelu neizrazite logike. Dobivena neizrazita pravila definiraju ponašanje određene varijante tehničkog sustava. No uvijek ih je moguće nadopunjavati u slučaju nekih promjena, tj. u svrhu poboljšanja tehničkog sustava. Pravila ponašanja se zapisuju putem sustava odlučivanja baziranog na neizrazitoj logici (sa Mamdami modelom neizrazite logike).

Kao drugi primjer odabrana je klima komora, kakva se koristi za pripremu zraka u poslovnim objektima. Na osnovu predložene arhitekture sustava s njenim mogućim podsustavima, kreirani su matematički modeli sustava prikazani u prostoru stanja.

Kao i u prvom primjeru variranjem odabranih utjecajnih parametara, dijelom dobivenih iz matematičkog modela kao što su vanjska temperatura, protok zraka, geometrije klima komore (površina poprečnog presjeka), te parametara iz MPC metode kao što je težinski faktor, ispitivalo se ponašanje tehničkog sustava. Na osnovu dobivenih podataka kreirala su se neizrazita pravila ponašanja sustava, također koristeći odlučivanje bazirano na Mamdani modelu neizrazite logike.

7.4. Smjerovi mogućih budućih istraživanja

Provedenim istraživanjem, došlo se do nekih ideja, kao mogućih smjerova budućih istraživanja u sklopu algoritma razvoja arhitektura složenih tehničkih sustava, koji nam omogućava obostrano preslikavanje podataka između modela strukture i ponašanja sustava u neizvjesnim situacijama. Mogući smjerovi budućih istraživanja mogu biti:

1. Prema Teoriji tehničkih sustava, moguće je napraviti integraciju modela sustava i tehničkog procesa pa bi bilo zanimljivo vidjeti na koji način neki parametri sustava utječu na provedbu samog tehničkog procesa i obrnuto tijekom neizvjesnih radnih uvjeta.
2. Algoritam bi se trebalo proširiti na mogućnost praćenja promjena na nivou komponenata podsustava, tj. koju komponentu treba eventualno dodati ili maknuti iz arhitekture podsustava da bismo dobili njegovo zadovoljavajuće ponašanje i stabilno stanje rada tehničkog sustava tijekom neizvjesnih radnih uvjeta.
3. Proširiti domenu strukture (ovdje prikazanu u matričnom zapisu – pomoću matrice komponenata DSM) na više domena (više domensku matricu – MDM). Kao domene bi se odabrali zahtjevi, tehnički proces i funkcije proizvoda, te bi se istražilo kako promjene u interakcijama u pojedinoj domeni utječu na interakcije u ostalim domenama.
3. U ovom radu, promatrani su samo linearni sustavi, odnosno sustavi koje je postupkom linearizacije moguće svesti na linearni oblik sustava. Trebalo bi probati proširiti i istražiti primjenu algoritma na izrazito nelinearne tehničke sustave, kao što su npr. sustavi letjelica ili ronilica. U takvim sustavima bi se moralo uzeti u obzir njihove nelinearnosti, te bi bilo interesantno istražiti kako to utječe na njihovo ponašanje, kao i samu stabilnost tehničkog sustava.

4. Istražiti mogućnost primjene neke druge metode upravljanja. Recimo, za ovakve procese bi zanimljivo bilo istražiti samoudešavajući modelski prediktivni regulator ili proširiti MPC metodu s neuronskom mrežom.
5. Poboljšati mogućnosti sustava odlučivanja, uvođenjem neuronske mreže koja bi nam služila u razvoju algoritma učenja odlučivanja, baziranog na neizrastnoj logici čime bismo pridonijeli učinkovitijem i bržem odlučivanju.
6. U doktorskom radu razvijen je algoritam za rane faze u procesu razvoja proizvoda. Ako bi se to željelo proširiti do faze detaljiranja, neminovno bi bilo uvesti u operaciju modeliranja ponašanja sustava neku od numeričkih metoda, te na osnovu toga razviti novi ili poboljšati već ovaj predloženi algoritam.
7. Kao što je već bilo spomenuto u točki 7.2. ovog poglavlja, u radu je kod modeliranja ponašanja sustava korištena samo teoretska analiza. Za dobivanje točnijeg matematičkog modela, u budućnosti bi bilo dobro istražiti primjenu neke od metoda identifikacije u modeliranju sustava. No zbog trenutne nemogućnosti provedbe takvog eksperimenta (u realnim uvjetima rada), to nije bio predmet istraživanja u ovom doktorskom radu. Time bi se mogla zaokružiti cjelina i napravio bi se snažniji korak ka implementaciji predloženog algoritma.

LITERATURA

- [1] Simpson, T. W., Siddique, Z., Jiao, J.: *“Product Platform and Product Family Design: Methods and Applications”*, Springer Science+Business Media, New York, 2006.
- [2] Anggraeni, N., Maltzahn, S., Anderl, L.: *“Similarity-based Concept Development for Modular Platform Systems”*, In: *Proceedings of ICED’13*, Seoul, Korea, 2013.
- [3] Robertson, D., Ulrich, K.: *“Planning for Product Platforms”*, *Sloan Management Review*, Vol. 39, No. 4, pp. 19-31, 1998.
- [4] Diepold, K.J., Winkler, F.J., Lohmann, B.: *„Systematical hybrid state modelling of complex dynamical systems: The quad - I/HS framework”*, In: *Mathematical and Computer Modelling of Dynamical Systems*, 16(4), pp. 347 – 371, 2010.
- [5] Strogatz, S.H.: *” Exploring complex networks”*, *Nature* 410, pp. 268–276, 2001.
- [6] Diepold, K.J., Winkler, F.J., Lohmann, B., Kortler, S.: *“A Framework for DSM-based Pre-modelling Analysis of Complex Systems”*, In: *Proceedings of the 11th International Design Structure matrix Conference, DSM’ 09*, Greenville, USA, 2009.
- [7] Diepold, K.J., Biedermann, W., Eben, K.G.M. Kortler, S., Lohmann, B., Lindemann, U.: *„Combining Structural Complexity Management and Hybrid Dynamical System Modelling”*, In: *Proceedings of DESIGN 2010*, Dubrovnik, Croatia, vol. 2, pp. 1045 – 1054, 2010.
- [8] Ulrich, K.: *“The role of product architecture in the manufacturing firm”*, *Research policy*, Vol.24, No. 3, pp.419-440, 1995.

-
- [9] Wyatt, D.F., Wynn, D.C., Jarett, J.P., Clarkson, P.J.: "Supporting product architecture design using computational design synthesis with network structure constraints", *Research in Engineering Design*, 23, pp. 17-52, 2011.
- [10] Hubka, V., Eder, W.E.: „Engineering Design: General Procedural Model of Engineering Design”, Springer – Verlag Berlin Heidelberg, Germany, 1992.
- [11] Hubka, V., Eder, W.E.: "Theory of Technical Systems – A Total Concept Theory for Engineering Design", Springer – Verlag Berlin Heidelberg, Germany, 1988.
- [12] Stark, R., Krause, F. L., Kind, C., Rothenburg, U., Müller, P., Hayka, H., Stöckert, H.: "Competing in engineering design—The role of Virtual Product Creation", *CIRP Journal of Manufacturing Science and Technology*, Vol. 3, pp. 175-184, 2010.
- [13] Kota, S., Chakabarti, A.: "A Method for Evaluation of Product Lifecycle Alternatives under Uncertainty", In: *Proceedings of ICED '09*, pp. 289-300, 2009.
- [14] Hansen, C.T., Andreasen, M.M.: "Two approaches to synthesis based on the domain theory", In *Engineering Design Synthesis*, (ed. A. Chakrabarti), chapter 6, Springer – Verlag London Limited, United Kingdom, pp. 93 – 108, 2002.
- [15] Kortler, S., Kohn, A., Lindemann, U.: „Validation of Product Properties Considering a High Variety of Complex Products“, In: *Proceedings of DESIGN 2012*, Dubrovnik, Croatia, vol. 3, pp. 1731 – 1740, 2012.
- [16] Lindemann, U., „Methodische Entwicklung technischer Produkte: Methoden flexible und situationsgerecht anwenden“ Springer, Berlin, 2006.
- [17] Mathias, J., Kloberdanz, H., Engelhardt, R., Birkhofer, H.: „Integrated Product and Process Development Based on Robust Design Methodology”, In: *Proceedings of ICED '09*, pp. 169-180, 2009.
- [18] Mathias, J., Kloberdanz, H., Engelhardt, R., Birkhofer, H.: „Strategies and Principles to Design Robust Products“, In: *Proceedings of DESIGN 2010*, Dubrovnik, Croatia, vol. 3, pp. 341 – 350, 2010.
- [19] Taguchi, G.: "Taguchi on Robust Technology Development: Bringing Quality Engineering Upstream", ASME Press, New York, 1993.
- [20] Diepold, K.J., Winkler, F.J., Lohmann, B.: "Discrete-Modelling of Process Components Interactions Using the Design Structure Matrix", In: *Proceedings of the 6th Vienna International Conference on Mathematical Modelling*, Vienna, Austria, 2009.
- [21] Biedermann, W., Diepold, K.J., Lindemann, U., Lohmann, B.: „Delimiting Structural and Dynamical System Analysis in Engineering Management“, In: *Proceedings of DESIGN 2012*, Dubrovnik, Croatia, vol. 3, pp. 1649 – 1656, 2012.

-
- [22] Blessing, L. T. M, Chakrabarti, A.: „*DRM, a Design Research Methodology*“, Springer Verlag London, 2009.
- [23] Lindemann, U., Maurer, M., Braun, T.: “*Structural Complexity Management – An Approach for the Field of Product Design*“, Springer Verlag, Berlin, Heidelberg, Germany, 2009.
- [24] Kreimeyer, M., Lindemann, U.: “*Complexity Metrics in Engineering Design – Managing the Structure of Design Processes*“, Springer-Verlag, Berlin Heidelberg 2011.
- [25] Diestel, R.: „*Graph Theory*“, Springer – Verlag, New York, 2000.
- [26] Steward, D. V.: “*The Design Structure System: A Method for Managing the Design of Complex Systems*“, *IEEE Transactions on Engineering Management* 28, pp. 71-74, 1981.
- [27] Browning, T.R.: “*Applying the design structure matrix to system decomposition and integration problems: A review and new directions*“, *IEEE Transactions on Engineering Management*, Vol. 48, No. 3, pp. 292-306, 2001.
- [28] Danilovic, M., Börjesson, H.: “*Managing the multiproject environment*“, In: *Proceedings of the Third Dependence Structure Matrix (DSM) International Workshop*, Cambridge, USA, 2001.
- [29] Danilovic, M., Börjesson, H.: “*Participatory dependence structure matrix approach*“, In: *Proceedings of the Third Dependence Structure Matrix (DSM) International Workshop*, Cambridge, USA, 2001.
- [30] Danilovic, M., Sigemyr, T.: “*Multiplan – A new multi-dimensional DSM-tool*“, In: *Proceedings of the 5th Design Structure Matrix Workshop*, Cambridge, UK, 2003.
- [31] Danilovic, M., Browning, T.: *A formal approach for domain mapping matrices (DMM) to complement design structuring matrices (DSM)*, In: *Proceedings of the 6th Design Structure Matrix (DSM) International Workshop*, Cambridge, UK, 2004.
- [32] Danilovic, M., Browning, T. R.: “*Managing complex product development projects with design structure matrices and domain mapping matrices*“, *International Journal of Project Management* 25 (2007) 3, pp. 300-314.
- [33] Kecman, V.: „*Dinamika procesa*“, *Fakultet strojarstva i brodogradnje*“, Zagreb, Hrvatska, 1990.
- [34] Ban, Ž.: „*Modeliranje i simuliranje sustava*“, skripta, *Fakultet elektrotehnike i računarstva*, Zagreb, Hrvatska, 2004.
- [35] Close, C.M., Fredrick, D.H., Newell, J.C.: „*Modelling and Analysis of Dynamic Systems*“, third edition, John Wiley & Sons, Inc., USA, 2002.

-
- [36] Buss, M., Glocker, M., Hardt, M., von Stryk, O., Bulirsch, R., Schmidt, G.: „Nonlinear Hybrid Dynamical Systems: Modelling, Optimal Control, and Applications”, In: *Analysis and Design of Hybrid Systems - Lecture Notes in Control and Information Science (LNCIS)*, Springer Berlin, pp. 311–335, 2002.
- [37] Henzinger, T.: “The theory of hybrid automata”, In *Verification of Digital and Hybrid Systems*, volume 170 of *NATO Advanced Study Institute Series F: Computer and Systems Sciences*, Springer, pp. 265–292, 2000.
- [38] Norvig, A.: “Object-Oriented Development of Simulation Models for Complex Hybrid Systems: Modeling, Optimal Control, and Applications, in *Analysis and Design of Hybrid Systems*”, *Lecture Notes in Control and Information Science (LNCIS)*, Springer, Berlin, Germany, pp. 132–149, 2002.
- [39] Hubbard, D.: “How to Measure Anything: Finding the Value of Intangibles in Business”, John Wiley & Sons, USA, 2007.
- [40] Kreye, M.E., Goh, Y.M., Newnes, L.B.: „Uncertainty in Through Life Costing Within the Concept of Product Service Systems: A Game Theoretic Approach“, In: *Proceedings of the 8th International Conference on Engineering Design, ICED 2009*, Stanford, USA, 2009.
- [41] De Weck, O., Eckert, C., Clarkson, P.J.: „A classification of uncertainty for early product and system design”, In: *Proceedings of International Conference in Engineering Design, ICED 2007*, Paris, France, pp. 1-12, 2007.
- [42] Antonsson, E.K., Otto, K.N.: “Imprecision in Engineering Design”, *Journal of Mechanical Design*, 117(B), pp. 25-32, 1995.
- [43] Newell, A., Simon, K.A.: “Human Problem Solving”, Prentice Hall, Engelwood Cliffs, New Jersey, 1972.
- [44] Vamos, T.: “Epistemic background problems of Uncertainty”, In: *IEEE International Symposium of Uncertainty Modeling Analysis*, pp. 96-100, 1990.
- [45] Kreye, M.E., Goh, Y.M., Newnes, L.B.: „Manifestation of Uncertainty – A Classification“, In: *Proceedings of the 9th International Conference on Engineering Design, ICED 2011*, Kobenhaven, Denmark, 2011.
- [46] Walker, W.E., Harremoes, P., Rotmans, J., Van der Sluijs, J.P., Van Asselt, M.B.A., Janssen, P., Krauss, K.V. "Defining uncertainty: a conceptual basis for uncertainty management in model based decision support". *Integrated Assessment*, 4(1), pp. 5-17, 2003.
- [47] Van der Sluijs, J.P., Craye, M., Funtowicz, S., Klopogge, P., Ravetz, J., Risbey, J. "Combining Quantitative and Qualitative Measures of Uncertainty in Model-Based

- Environmental Assessment: The NUSAP System". Risk Analysis: An International Journal*, 25(2), pp. 481-492, 2005.
- [48] Oberkamp, W.L., DeLand, S.M., Rutherford, B.M., Diegert, K.V., Alvin, K.F.: "Error and uncertainty in modeling and simulation", *Reliability Engineering and System Safety*, 75(2002), pp. 333-357, 2002.
- [49] Krzykacz-Hausmann, B.: "An approximate sensitivity analysis of results from complex computer models in the presence of epistemic and aleatory uncertainties", *Reliability Engineering & System Safety*, 91(10-11), pp. 1210-1218, 2006.
- [50] Thunnissen, D.P.: "Uncertainty Classification for the Design and Development of Complex Systems". In: *PMC2003 - 3rd Annual Predictive Methods Conference*. Newport Beach, California, USA, 2003.
- [51] Ghirardato, P., Maccheroni, F., Marinacci, M.: "Revealed Ambiguity and Its Consequences: Updating", *Advances in Decision Making Under Risk and Uncertainty*, Springer-Verlag, Berlin-Heidelberg, pp. 3-18, 2008.
- [52] Morone A., Morone, P.: "Guessing Games and People Behaviours: "What Can We Learn?"", *Advances in Decision Making Under Risk and Uncertainty*, Springer Verlag, Berlin Heidelberg, 2008.
- [53] Courtney, H.: "20/20 Foresight: Crafting Strategy in an Uncertain World ", Harvard Business School Press, 2001.
- [54] Goh, Y.M., McMahon, C.A., Booker, J.D.: "Development and characterization of error functions in design", *Research in Engineering Design*, 18(3), pp. 129-149, 2007.
- [55] Moens, D., Vandepitte, D.: "Non-probabilistic approaches for non-deterministic dynamic FE analysis of imprecisely defined structures", In: *ISMA2004 - International Conference on Noise and Vibration Engineering*, Leuven, Belgium, pp. 3095-3120, 2004.
- [56] Dubois, D., Fargier, H., Sabbadin, R.: "Qualitative Decision Rules under Uncertainty", In: *ECSQARU - 7th European Conference on Symbolic and Quantitative Approaches to Reasoning with Uncertainty* Aalborg, Denmark 2003.
- [57] Knetsch, T.: "Unsicherheiten in Ingenieurberechnungen", Shaker-Verlag, Aachen, 2004.
- [58] Hicks, B.J., Culley, S.J., Allen, R.D., Mullineux, G.: A framework for the requirements of capturing, storing and reusing information and knowledge in engineering design, *International Journal of Information Management* 22, 263–280, 2002.
- [59] Refsgaard, J.C., van der Sluijs, J.P., Brown, J., van der Keur, P.: "A framework for dealing with uncertainty due to model structure error". *Advances in Water Resources*, 29(11), pp. 1586-1597, 2006.

-
- [60] ...SFB 805 – “Control of Uncertainty in Load Carrying Structures in Mechanical Engineering”, Report of Subprojects, Darmstadt, Germany, 2011.
- [61] Engelhardt, R., Koenen, J., Enss, G., Sichau, A., Platz, R., Kloberdanz, H., Birkhofer, H., Hanselka, H.: „A Model to Categorise Uncertainty in Load-Carrying Systems“. In: *Proceedings of MMEP Conference 2010*, Cambridge, UK, pp. 53-64, 2010.
- [62] Engelhardt R., Koenen J., Brenneis M., Kloberdanz H., Bohn A.: „An approach to classify methods to control uncertainty in load-carrying structures“, *Applied Mechanics and Materials*, Vol. **104**(3), pp. 33-44, 2012.
- [63] Schnieder, E.: “Methoden der Automatisierung. Beschreibungsmittel, Modellkonzepte und Werkzeuge für Automatisierungssysteme”, Braunschweig, Wiesbaden. Vieweg, Germany, 1999.
- [64] Wasson, C. S.: “System Analysis, Design, and Development Concepts, Principles, and Practices”. Hoboken, New Jersey: Wiley-Interscience, 2006.
- [65] Boardman, J., Sauser, B.: “System of Systems - the meaning of”, *Proceedings of the 2006 IEEE/SMC International Conference on System of Systems Engineering*, Los Angeles, pp. 6-12, 2006.
- [66] Rechtin, E.: “Systems Architecting - Creating & Building Complex Systems”, Englewood Cliffs, New York, Prentice Hall, 1991.
- [67] Patzak, G.: „Systemtechnik – Planung komplexer, innovativer Systeme“, Berlin, Springer, 1982.
- [68] Rind, D.: “Complexity and Climate”, *Science*, Vol. 284, issue 5411, pp. 105-107, 1999.
- [69] Ulrich, K.T, Eppinger, S.D.: “Product design and development “, 3rd edition, McGraw-Hill, Boston, USA, 2004.
- [70] Lanner, P., Malmqvist, J.: “An Approach towards considering technical and economic aspects in product architecture design”. In: *Proceedings of the 1st International Nord Design Seminar on Engineering Design*, Espoo, 1996.
- [71] Erens, F., Verhulst, K.: “Architecture for Product Families”, In: *Proceedings of the 2th WDK Workshop on Product Structuring*, Delft, 1996.
- [72] Vukić, Z., Kuljača, Lj.: “Automatsko upravljanje – analiza linearnih sustava”, Kigen, Zagreb, Hrvatska, 2005.
- [73] Šerman, N.: „Dinamika procesa“, skripta, Fakultet strojarstva i brodogradnje, Zagreb, Hrvatska, 2002.
- [74] Perić, N.: „Automatsko upravljanje – predavanja“, skripta, Fakultet Elektrotehnike i računarstva, Zagreb, Hrvatska, 2001.

-
- [75] Babić, H.: „Signali i sustavi“, skripta, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska, 1996.
- [76] Vukić, Z., Kuljača, Lj., Donlagić, D., Tešnjak, S.: „Nonlinear Control Systems“, Control Engineering Series, Marcel Dekker, Inc., New York – Basel, 2003.
- [77] Matika, D.: “Sustavi digitalnog upravljanja”, Graphis, Zagreb, Hrvatska, 2005.
- [78] Engell, S., Frehse, G., Schnieder, E. (Eds.): “Modelling, Analysis, and Design of Hybrid Systems”, Springer-Verlag Berlin Heidelberg New York, 2002.
- [79] Ljapunov, A.M.: “The General Problem of the Stability of Motion, PhD thesis, Ann. Math. Studies, Princeton University Press, New Jersey, 1949.
- [80] Kasač, J.: „Opća teorija sustava – predavanja“, skripta, Fakultet strojarstva i brodogradnje, Zagreb, Hrvatska, 2007.
- [81] Tomiyama, T., Gu, P., Jin, Y., Lutters, D., Kind, Ch., Kimura, F.: “Design methodologies: Industrial and educational applications”, CIRP Annals – Manufacturing Technology, 58, pp. 543-565, 2009.
- [82] Simon, H.A.: “The New Science of Management Decision”, Harper and Row, New York, USA, 1960.
- [83] Keeney, R.L.: “Stimulating Creative Design Alternatives Using Customer Values”, IEEE Transactions on Systems Man and Cybernetics Part C Applications and Reviews 34(4), pp. 450–459, 2004.
- [84] Suh, N.P.: “The Principles of Design”, Oxford University Press, Oxford, 1990.
- [85] Howard, R.A., Matheson, J.E.: “Readings on the Principles and Applications of Decision Analysis”, 2 Volumes, Strategic Decisions Group, Menlo Park, CA, USA, 1984.
- [86] Keeney, R.L., Raiffa, H.: “Decisions with Multiple Objectives: Preferences and Value Trade-offs”, Cambridge University Press, Cambridge, USA, 1993.
- [87] Antonsson, E.K., Otto, K.N.: “Imprecision in Engineering Design”, Journal of Vibration and Acoustics 117 B, pp. 25–32, 1995.
- [88] Aughenbaugh, J.M., Paredis, C.J.J.: “The Value of Using Imprecise Probabilities in Engineering Design”, Journal of Mechanical Design, 128(4), pp. 969–979, 2006.
- [89] Li, H., Azarm, S.: “Product Design Selection under Uncertainty and With Competitive Advantage”, Journal of Mechanical Design, 122(4), pp. 411–418, 2000.
- [90] Marston, M, Mistree, F.: “An Implementation of Expected Utility Theory in Decision Based Design”, In: Proceedings of the 1998 ASME DETC, Paper DETC98/DTM-5670, ASME Press, 1998.

-
- [91] Hazelrigg, G.A.: "A Framework for Decision-based Engineering Design", *Journal of Mechanical Design*, 120(4), pp. 653–658, 1998.
- [92] Von Neumann, J., Morgenstern, O.: "Theory of Games and Economic Behavior",. Princeton University Press, USA, 1943.
- [93] Bras, B, Mistree, F.: "Designing Design Processes in Decision-based Concurrent Engineering", *SAE Transactions*, 100(5), pp. 1019–1040, 1991.
- [94] Mistree, F., Hughes, O.F., Bras, B.: "Compromise Decision Support Problem and the Adaptive Linear Programming Algorithm", *Structural Optimization: Status and Promise*, American Institute of Aeronautics & Astronautics, pp. 251–290, 1993.
- [95] Jin, Y, Danesh, M.R.: "Value Aggregation for Collaborative Design Decisionmaking", *Decision Making in Engineering Design*, ASME Press, New York, USA, pp. 291–301, 2006.
- [96] Simon, R., St.Clair, R.K.: "The Systems Approach: Fresh Solutions to Complex Problems Through Combining Science and Practical Common Sense",. Anaheim, CA: KNI, Inc., USA, 1998.
- [97] ... "NASA System Engineering Handbook", NASA/SP-2007-6105 Rev. 1, National Aeronautics and Space Administration NASA Headquarters, Washington, USA; 2007.
- [98] Sage, A.P., Olson, S.R.: "Modeling and Simulation in Systems Engineering - Whither Simulation Based Acquisition?", *Simulation*, 76(2), pp. 90-91, 2001.
- [99] ... VDI 2206: "Entwicklungsmethodik für mechatronische Systeme (Development methodology for mechatronic systems)", Beuth Verlag, Berlin, 2004.
- [100] ... IEEE Trial-Use Recommended Practice for Distributed Interactive Simulation - Verification, Validation, and Accreditation. IEEE Std. 1278.4, I. C. Society, 1997.
- [101] Perić, N., Petrović, I.: „Automatizacija postrojenja i procesa – predavanja“, skripta, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska, 2001.
- [102] Williams II, R.L., Lawrence, D.A.: "Linear State – Space Control Systems", John Wiley & Sons, Ltd., New Jersey, USA, 2007.
- [103] Perić, N., Petrović, I.: „Identifikacija procesa – predavanja“, skripta, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska, 2005.
- [104] Janschek, K.: "Mechatronic Systems Design – Methods, Models, Concepts", Springer-Verlag Berlin Heidelberg, 2012.
- [105] Camacho, E.F., Bordons, C.: "Model Predictive Control", Springer – New York, USA, 2004.

-
- [106] Muske, K.R., Rawlings, J.: "Model Predictive Control with Linear Models", *AIChE Journal*, 39, pp. 262-287, 1993.
- [107] Bego, O.: "Predikcijsko upravljanje procesima s više ulaza i izlaza", doktorska disertacija, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska, 2005.
- [108] Zadeh, L.A.: "Fuzzy sets", *Information and Control*, 8, pp. 338–353, 1965.
- [109] Zadeh, L.A.: "Fuzzy algorithms", *Info & Ctl.*, Vol. 12, pp. 94-102, 1968.
- [110] Lončar, D.: "Primjena neizrazite logike u regulacijskom sustavu termoeenergetskog bloka", doktorska disertacija, Fakultet strojarstva i brodogradnje, Zagreb, Hrvatska, 2001.
- [111] Babuska, R., Verbruggen, H.B., Hellendorn, H.: „Promising fuzzy modelling and control methodologies for industrial applications“, In: *Proceedings of European Symposium on Intelligent technologies*“, ESIT '99, Crete, Greece, 1999.
- [112] Kosko, B.: "Fuzzy Thinking", *The New Science of Fuzzy Logic*, Hyperion, New York, 1993.
- [113] Ross, T.J.: „Fuzzy Logic with Engineering Applications“, third edition, John Wiley & Sons, Ltd., USA, 2010.
- [114] Sivanandam, S.N., Sumathi, S., Deepa, S.N.: "Introduction to Fuzzy Logic using MATLAB", Springer – Verlag, Berlin Heidelberg, 2007.
- [115] Kasač, J.: "Neizrazita logika – predavanja", Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, 2013.
- [116] Jang, J.-S., R., Sun, C.-T., Mizutani, E.: "Neuro-fuzzy and Soft computing", Prentice Hall, 1997.
- [117] Mamdani, E.H., Assilian, S.: "An experiment in linguistic synthesis with a fuzzy logic controller", *International Journal of Man-machine Studies*, 7(1), pp. 1-13, 1975.
- [118] Takagi, T., Sugeno, M.: "Fuzzy identification of systems and its applications to modeling and control", *IEEE Transactions on Systems, Man and Cybernetics*, 15, pp. 116-132, 1985.
- [119] Pimmler, T. U., Eppinger, S. D.: "Integration Analysis of Product Decompositions", *Proceedings of the 1994 ASME Design, Theory and Methodology Conference*, Minneapolis, USA, 1994.
- [120] Kalman, R.E.: "Mathematical description of linear dynamical systems", *Journal of Control*, SIAM Ser. A, 1(2), pp. 152-192, 1963.
- [121] Perić, N.: „Automatsko upravljanje – predavanja“, skripta, Fakultet Elektrotehnike i računarstva, Zagreb, Hrvatska, 2001.

-
- [122] Perić, N., Vašak, M.: „Procesna automatizacija – predavanja“, skripta, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska, 2010.
- [123] Perić, N., Petrović, I.: „Inteligentno upravljanje sustavima – predavanja“, skripta, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska, 2001.
- [124] Isermann, R.: „Digital Control Systems“, 2nd edition, Springer – Verlag, 1989.
- [125] Ščap, D.: „Prenosila i dizala – podloge uz predavanja“, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, Hrvatska, 2004.
- [126] Ščap, D.: „Prenosila i dizala – podloge za konstrukciju i proračun“, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, Hrvatska, 1989.
- [127] Osman, K., Štorga, M., Marjanović, D.: „An Approach to Nonlinear Behaviour Prediction of Technical Systems“, *Proceedings of the 13th International Design Conference DESIGN 2014, Dubrovnik, Croatia, pp. 1307-1318, 2014.*
- [128] ...LOOME0, katalog, Tesseon, Germany, 2012.
- [129] ...”MANNESMANN Demag – Komponenten Handbuch ‘95/’96”, katalog, Germany, 1995.
- [130] ...”MANNESMANN Demag – Geared motors 1998”, katalog, Germany, 1998.
- [131] Bazjanac, D.: „Tehnička mehanika III – dinamika“, Sveučilište u Zagrebu, Zagreb, Hrvatska, 1974.
- [132] Opalić, M.: „Prijenosnici snage i gibanja“, Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, Hrvatska, 1998.
- [133] Decker, K.-H.: „Elementi strojeva“, Golden Marketing, Tehnička knjiga, Zagreb, Hrvatska, 2006.
- [134] Dresig, H., Holzweißig, F.: „Dynamics of Machinery – Theory and Applications“, Springer-Verlag, Berlin Heidelberg, Germany, 2010.
- [135] Kraut, B.: „Krautov strojarski priručnik“, Axiom, Zagreb, Hrvatska, 1997.
- [136] Feyrer, K.: „Wire Rops – Tension, Endurance, Reliability“, Springer – Verlag Berlin Heidelberg, Germany, 2007.
- [137] ...MATLAB, User's guide, documentation, MathWorks, 2012.
- [138] ...MATLAB Model Predictive Control Toolbox, User's guide, documentation, MathWorks, 2012.
- [139] ...MATLAB Fuzzy Logic Toolbox, User's guide, documentation, MathWorks, 2012.

-
- [140] Osman, K., Štorga, M., Stanković T., Marjanović, D.: "Behaviour Prediction Framework in System Architecture Development", *Applied Mechanics and Materials*, 104(3), pp. 3-12, 2011.
- [141] Donjerković, P. "Osnove i regulacija sustava grijanja, ventilacije i klimatizacije", II dio, Alfa, Zagreb, Hrvatska, 1996.
- [142] ...EN 1886 – Ventilation for buildings – Air Handling Units – Mechanical Performance, 1998.
- [143] Osman, K.: „Upravljanje postrojenjem klimatizacije poslovnog objekta“, magistarski rad, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska, 2011.
- [144] Santro, I.: „Samoudešavajući poopćeni predikcijski regulator“, magistarski rad, Fakultet elektrotehnike i računarstva, Zagreb, Hrvatska, 1997.
- [145] Galović, A.: "Termodinamika II", Fakultet strojarstva i brodogradnje, Sveučilište u Zagrebu, Zagreb, Hrvatska, 2010.
- [146] Švaić, S.: „Elementi gradnje aparata“, skripta, Fakultet strojarstva i brodogradnje", Sveučilište u Zagrebu, Zagreb, Hrvatska, 1997.
- [147] Halasz, B., Galović, A., Boras, I.: "Toplinske tablice", Fakultet strojarstva i brodogradnje, Zagreb, Hrvatska, 2010.
- [148] Recknagel, H., Sprenger, E., Schramek, E.-R., Čeperković, S.: "Grijanje i klimatizacija sa pripremom tople vode i rashladnom tehnikom", Interklima, Vrnjačka Banja, Srbija, 2002.

Krešimir Osman rođen je 1973. godine u Zagrebu, gdje završava osnovnu i srednju školu, Strojarsku tehničku školu „Fran Bošnjaković“. Godine 1992. upisuje Fakultet strojarstva i brodogradnje, Zagreb, gdje 1997. godine diplomira na VI stupnju, smjer: strojarske konstrukcije, a 1999. godine na VII stupnju, smjer: procesno-energetski, usmjerenje: termotehnika. Tokom studija dobio je dvije nagrade i to: Rektorovu nagradu 1998. godine i Nagradu Fakulteta strojarstva i brodogradnje 1999. godine.

Od 2000. do 2007. godine radi kao projektant u firmi „I.B.R. INŽENJERING Cirković“ d.o.o. u Zagrebu, gdje se bavi projektiranjem sustava grijanja, ventilacije i klimatizacije, te procesne regulacije. Također od 2005. do 2007. godine radio je kao konstruktor – vanjski suradnik u firmi „Promatis“ d.o.o. u Zagrebu na poslovima oblikovanja i konstruiranja kućišta za električne uređaje.

Od 2005. do 2007. godine bio je zaposlen kao asistent - vanjski suradnik na Zavodu za konstruiranje, Katedra za elemente strojeva i konstrukcije. Od 2007. do 2014. godine bio je zaposlen kao znanstveni novak – asistent na Zavodu za konstruiranje, Katedra za razvoj proizvoda i konstruiranje na projektu Ministarstva znanosti, obrazovanja i športa 120-1201829: „Modeli i metode upravljanja znanjem u razvoju proizvoda“. Od 2007. godine radi i kao honorarni asistent na Strojarskom i Informatičkom odsjeku Tehničkog veleučilišta u Zagrebu. Sudjeluje u nastavi izvođenjem vježbi iz različitih kolegija.

Tokom 2009. godine završava međunarodni doktorandski seminar “European Summer School on Engineering Design Research” u organizaciji Danskog tehničkog sveučilišta, Tehničkog sveučilišta u Luksemburgu, te Tehničkog sveučilišta Ilmenau. Također tokom 2011. godine završava doktorandski seminar „TUM Spring School on System Engineering“ u organizaciji Tehničkog sveučilišta u Munchenu i Stevens Instituta iz New Jersey.

Godine 2011. završava poslijediplomski znanstveni magistarski studij na Fakultetu elektrotehnike i računarstva, Sveučilišta u Zagrebu, znanstveno polje: elektrotehnika, smjer: automatika, s temom magistarskog rada: „Upravljanje postrojenjem klimatizacije poslovnog objekta“. Godine 2002. upisuje poslijediplomski znanstveni doktorski studij na Fakultetu strojarstva i brodogradnje, Sveučilište u Zagrebu, na smjeru „Teorija konstrukcija“, gdje je odslušao i položio sve ispite.

Od 2008. godine, aktivno sudjeluje u organizaciji međunarodnih znanstvenih konferencija DESIGN, koje se održavaju svake parne godine u Cavtatu, Hrvatska.

Kao autor ili koautor objavio je nekoliko znanstvenih i stručnih radova u Hrvatskoj i inozemstvu.

Služi se engleskim i njemačkim jezikom.

CURRICULUM VITAE

Krešimir Osman was born on 1973 in Zagreb, Croatia where he finished elementary and high school, High school of engineering „Fran Bošnjaković“. On 1992 he starts to attend Faculty of Mechanical Engineering and Naval Architecture, Zagreb, where he graduate twice 1997 as a Bachelor of Science on VI degree program, and 1999 as Diploma Engineer on VII degree program, both on field: Mechanical engineering. During the study he got two awards, Rector Award 1998 and Award of FMENA, 1999 year for the best student project.

From 2000 to 2007 he worked as mechanical designer of HVAC systems and process control in company “I.B.R. INŽENJERING Cirković”, Zagreb. Also from 2005 to 2007 he worked as mechanical designer – associate employee as mechanical designer of embodiment and detail design of electrical device housing in company “Promatis”, Zagreb.

In 2005 year he started to work on Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb, as an associate assistant on Department of Design, Chair of Machine Elements. From 2007 to 2014 he has been employed as a research assistant on the same faculty on Department of Design, Chair of Engineering Design and Product Development on the research project supported by the Ministry of Science, Education and Sports of the Republic of Croatia: „Models and methods in knowledge management in product development“. From 2007 he has been involved in the teaching at the study of Mechanical Engineering section and Informatics section at the Polytechnics of Zagreb. During this time he has been involved in teaching activities in various courses.

During the year 2009 he attended an international two-week PhD seminar “European Summer School on Engineering Design Research” organized by the Danish Technical University, Université du Luxembourg and Ilmenau University of Technology. Also, during year 2011, he attended an international PhD seminar “TUM Spring School on System Engineering” organized by Technische Universität München and Stevens Institute of Technology from New Jersey, USA.

In 2011 he acquired the M.Sc. degree at Faculty of Electrical Engineering and Computing, University of Zagreb with master thesis titled "Control of Air Conditioning Facility in Office Building", field: Electrical Engineering, profile: Control Engineering and Automatization. In 2002 he becomes a PhD student at Faculty of Mechanical Engineering and Naval Architecture, University of Zagreb, field: Theory of Engineering Design, where he completed and passed all courses.

Since 2008 he took an active part in the organization of the International Design Conferences DESIGN 2008, DESIGN 2010, DESIGN 2012 and DESIGN 2014 held in Cavtat, Croatia.

As the author or co-author he has published several scientific and technical papers in Croatia and abroad.

He has good command of the English language and basic knowledge of German language.